



TESIS - SS142501

**MODEL *HYBRID* GSTARX-ANN
UNTUK PERAMALAN DATA *SPACE-TIME*
DENGAN EFEK VARIASI KALENDER**

(Studi Kasus: Data *Inflow* dan *Outflow* Uang Kartal di
Bank Indonesia Wilayah Jawa Timur)

I MADE GDE MERANGGI DANA
NRP. 06211650010028

DOSEN PEMBIMBING
Dr. SUHARTONO, M.Sc.
Dr. SANTI PUTERI RAHAYU, M.Si.

PROGRAM MAGISTER
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018



THESIS - SS142501

**A HYBRID GSTARX-ANN MODEL
FOR FORECASTING SPACE-TIME DATA
WITH CALENDAR VARIATION EFFECT**
(Case Study: Inflow and Outflow Data in Bank Indonesia
East Java Region)

I MADE GDE MERANGGI DANA
NRP. 06211650010028

SUPERVISORS
Dr. SUHARTONO, M.Sc.
Dr. SANTI PUTERI RAHAYU, M.Si.

MAGISTER PROGRAMME
DEPARTEMEN OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018

**MODEL HYBRID GSTARX-ANN UNTUK PERAMALAN
DATA SPACE-TIME DENGAN EFEK VARIASI KALENDER
(STUDI KASUS: DATA INFLOW DAN OUTFLOW UANG
KARTAL DI BANK INDONESIA WILAYAH JAWA TIMUR)**

Tesis ini disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si.)

di


Institut Teknologi Sepuluh Nopember
oleh:

I MADE GDE MERANGGI DANA
NRP. 06211650010028

Tanggal Ujian : 16 Januari 2018
Periode Wisuda : September 2018

Disetujui oleh:


1. Dr. Suhartono, M.Sc. (Pembimbing I)
NIP. 19710929 199512 1 001

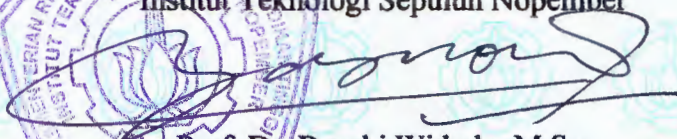

2. Dr. Santi Puteri Rahayu, M.Si. (Pembimbing II)
NIP. 19750115 199903 2 003


3. Dr. Kartika Fithriasari, M.Si. (Penguji)
NIP. 19691212 199703 2 002


4. Dr. R. Mohamad Atok, M.Si. (Penguji)
NIP. 19710915 199702 1 001

Dekan

Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember


Prof. Dr. Basuki Widodo, M.Sc.
NIP. 19650605 198903 1 002



MODEL *HYBRID* GSTARX-ANN UNTUK PERAMALAN DATA *SPACE-TIME* DENGAN EFEK VARIASI KALENDER (STUDI KASUS: DATA *INFLOW* DAN *OUTFLOW* UANG KARTAL DI BANK INDONESIA WILAYAH JAWA TIMUR)

Nama Mahasiswa : I Made Gde Meranggi Dana
NRP : 06211650010028
Pembimbing : Dr. Suhartono, M.Sc.
Co-Pembimbing : Dr. Santi Puteri Rahayu, M.Si.

ABSTRAK

Selain berdimensi waktu, data juga bisa berdimensi ruang yang dikenal dengan data *space-time*. Model *space-time* merupakan suatu model yang menggabungkan unsur dependensi waktu dan lokasi pada suatu data *time series* multivariat, salah satu model *space-time* adalah *Generalized Space-Time Autoregressive* (GSTAR). Model GSTAR memiliki keterbatasan yaitu tidak mampu memodelkan *time series* yang nonlinier, namun hal ini bisa diatasi dengan menerapkan model *hybrid* pada GSTAR. Pada penelitian ini akan dilakukan pemodelan *hybrid* GSTARX-ANN, dimana model GSTARX sebagai komponen linier yang melibatkan variabel prediktor, yaitu efek variasi kalender dan ANN sebagai komponen nonlinier. Model *hybrid* GSTARX-ANN merupakan model terbaik dalam meramalkan data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* linier maupun nonlinier dibandingkan model VARX dan GSTARX. Data *inflow* dan *outflow* di KPw BI wilayah Jawa Timur dipengaruhi oleh tren kebijakan BI, musiman, dan variasi kalender, serta mengandung unsur *nonlinearity*. Pengaruh minggu terjadinya hari raya Idul Fitri juga berpengaruh terhadap tingginya *inflow* dan *outflow*. Pada pemodelan data *inflow* di KPw BI wilayah Jawa Timur, model GSTARX-FFNN(8,2,1) bobot invers jarak merupakan model terbaik, sedangkan pada pemodelan data *outflow* model GSTARX-FFNN(8,15,1) merupakan model terbaik.

Kata Kunci: ANN, GSTARX, GSTARX-ANN, *space-time*, variasi kalender

Halaman ini sengaja dikosongkan

**A HYBRID GSTARX-ANN MODEL
FOR FORECASTING SPACE-TIME DATA
WITH CALENDAR VARIATION EFFECT
(CASE STUDY: INFLOW AND OUTFLOW DATA
IN BANK INDONESIA EAST JAVA REGION)**

Name : I Made Gde Meranggi Dana
NRP : 06211650010028
Supervisor : Dr. Suhartono, M.Sc.
Co-Supervisor : Dr. Santi Puteri Rahayu, M.Si.

ABSTRACT

Aside from time dimension, data can also dimension of space known as space-time data. The space-time model is a model that combines elements of time and location dependencies in a multivariate time-series data. One of the space-time models is Generalized Space-Time Autoregressive (GSTAR). The GSTAR model has its limitations of not being able for modeling a nonlinear time series, this can be overcome by applying hybrid model on GSTAR. In this research will be modeling hybrid GSTARX-ANN, where GSTARX model as a linear component involving predictor variable, that is an effect of calendar variation and ANN as a nonlinear component. The hybrid GSTARX-ANN model is the best model for predicting simulation data containing trend, seasonality, calendar variations, linear and nonlinear noise series compared to VARX and GSTARX models. Inflow and outflow data in Bank Indonesia East Java region are influenced by BI policy, seasonal trend, calendar variation, and contain nonlinearity elements. GSTARX-FFNN (8,2,1) is the best model for modeling inflow data in Bank Indonesia East Java region, while GSTARX-FFNN (8,15,1) is the best model for modeling outflow data.

Key Words: ANN, calendar variation, GSTARX, GSTARX-ANN, space-time

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Tuhan Yang Maha Esa atas segala berkah-Nya, penulis dapat menyelesaikan laporan tesis dengan judul

**“Model *Hybrid* GSTARX-ANN untuk Peramalan Data *Space-Time*
dengan Efek Variasi Kalender”.**

Penulis menyadari bahwa dalam penyusunan tesis ini tidak terlepas dari bantuan maupun dukungan dari berbagai pihak. Oleh karena itu, penulis menyampaikan rasa terima kasih kepada:

1. Bapak Dr. Suhartono, M.Sc. selaku Ketua Departemen Statistika dan dosen pembimbing bersama Ibu Dr. Santi Puteri Rahayu, M.Si. yang dengan sabar telah membimbing dan memberikan banyak ilmu yang sangat bermanfaat bagi penulis.
2. Bapak Dr. R. Mohamad Atok, M.Si. dan Ibu Dr. Kartika Fithriasari, M.Si. selaku dosen penguji yang telah memberikan banyak masukan dan arahan kepada penulis sehingga tesis ini dapat diselesaikan dengan baik.
3. Bapak Dr.rer.pol. Heri Kuswanto M.Si. selaku Ketua Program Studi Pascasarjana yang telah memberikan fasilitas, sarana, dan prasarana.
4. Dr. Purhadi, M.Sc. selaku dosen wali yang telah memberikan banyak saran dan arahan dalam proses belajar di Pascasarjana Statistika ITS.
5. Seluruh dosen Departemen Stasistika ITS, atas ilmu yang telah diberikan selama penulis berada di bangku kuliah.
6. Ibu dan Bapak tercinta, atas segala doa, kasih sayang, nasihat, dan dukungan yang selalu diberikan kepada penulis, serta Kak Luhtu Parinata dan Nyoman Dirgayusa atas kebersamaanya.
7. Sahabat penulis selama masa perkuliahan, Silvi, Bahagiati, Erna.
8. Rekan seperjuangan tesis, terkhusus Bahagiati, Kak Ratna, Kak Reni, Kak Aniq, Kak Sari atas motivasi dalam mengerjakan tesis.
9. Teman-teman Pascasarjana Statistika ITS angkatan 2016 yang telah memberikan pengalaman dan kebersamaan yang sangat berharga.
10. Semua pihak yang membantu dalam penyusunan tesis ini.

Penulis menyadari tesis ini masih banyak kekurangan, kritik dan saran yang membangun selalu penulis harapkan guna perbaikan di masa yang akan datang sehingga hasil dari tesis ini memberikan manfaat bagi pihak terkait.

Surabaya, Januari 2018

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
<i>TITLE PAGE</i>	iii
LEMBAR PENGESAHAN	v
ABSTRAK	vii
<i>ABSTRACT</i>	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxv
 BAB 1 PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	6
1.4 Manfaat Penelitian	6
1.5 Batasan Masalah	6
 BAB 2 TINJAUAN PUSTAKA	
2.1 Model ARIMA	9
2.2 <i>Time Series Multivariat</i>	11
2.2.1 Model <i>Vector Autoregressive Moving Average</i> (VARMA)	12
a. Identifikasi Model	12
i. <i>Matrix Cross Correlation Function</i> (MCCF)	13
ii. <i>Matrix Partial Cross Correlation Function</i> (MPCCF)	15
b. Estimasi Parameter	17
c. Cek Diagnostik	18
d. Pemilihan Model Terbaik	20
e. Peramalan	20
2.2.2 Model <i>Space Time Autoregressive</i> (STAR)	21

2.2.3 Model <i>Generalized Space Time Autoregressive</i> (STAR)	23
a. Penentuan Bobot Lokasi pada GSTAR	24
i. Bobot Seragam (<i>Uniform</i>)	25
ii. Bobot Biner	25
iii. Bobot <i>Invers</i> Jarak	26
iv. Bobot Normalisasi Korelasi Silang	27
v. Bobot Normalisasi Inferensi Parsial Korelasi Silang	28
b. Penaksiran Parameter Model GSTAR	29
i. Estimasi <i>Ordinary Least Square</i> (OLS)	29
ii. Estimasi <i>Generalized Least Square</i> (GLS)	32
c. Kondisi Stasioner Parameter Model GSTAR	34
d. Peramalan Model GSTAR	35
2.3 Uji Terasvirta	35
2.4 <i>Artificial Neural Network</i> (ANN)	36
2.5 Model Variasi Kalender	39
2.6 Model <i>Hybrid</i> GSTARX-ANN	41
2.7 Evaluasi Model	41
2.8 Penyetoran dan Penarikan Uang Rupiah di Bank Indonesia	42
BAB 3 METODOLOGI PENELITIAN	
3.1 Studi Simulasi	43
3.2 Kajian Terapan	45
3.2.1 Sumber Data dan Variabel Penelitian	45
3.2.2 Struktur Data	47
3.2.3 Langkah Analisis	49
a. Tahapan Pembentukan Model GSTARX	48
b. Tahapan Pembentukan Model <i>Hybrid</i> GSTARX-ANN	52
3.3 Syntax SAS Pemodelan VARX dan GSTARX	54
BAB 4 ANALISIS DAN PEMBAHASAN	
4.1 Pemodelan Data Simulasi	55
4.1.1 Pemodelan Data Simulasi Skenario I	56

a. Pemodelan Tahap Pertama Data Simulasi Skenario I	57
b. Pemodelan Tahap Kedua Data Simulasi Skenario I	61
Pemodelan Tahap Kedua Menggunakan VAR	61
Pemodelan Tahap Kedua Menggunakan GSTAR	66
Pemodelan Tahap Kedua Menggunakan GSTAR-FFNN	70
Pemodelan Tahap Kedua Menggunakan GSTAR-DLNN	73
c. Perbandingan Model VARX, GSTARX, dan <i>Hybrid</i> GSTARX- ANN pada Skenario I.....	78
4.1.2 Pemodelan Data Simulasi Skenario II	81
a. Pemodelan Tahap Pertama Data Simulasi Skenario II	82
b. Pemodelan Tahap Kedua Data Simulasi Skenario II	85
Pemodelan Tahap Kedua Menggunakan VAR	85
Pemodelan Tahap Kedua Menggunakan GSTAR	90
Pemodelan Tahap Kedua Menggunakan GSTAR-FFNN	92
Pemodelan Tahap Kedua Menggunakan GSTAR-DLNN	95
c. Perbandingan Model VARX, GSTARX, dan <i>Hybrid</i> GSTARX- ANN pada Skenario II	97
4.2 Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> di Jawa Timur	100
4.2.1 Karakteristik Data <i>Inflow</i> dan <i>Outflow</i> di KPw BI Jawa Timur	100
4.2.2 Pemodelan <i>Inflow</i> Tahap Pertama	106
4.2.3 Pemodelan <i>Inflow</i> Tahap Kedua	109
I. Pemodelan <i>Inflow</i> Tahap Kedua Menggunakan VAR	109
II. Pemodelan <i>Inflow</i> Tahap Kedua Menggunakan GSTAR	115
a. Bobot Seragam	115
b. Bobot Invers Jarak	117
c. Bobot Normalisasi Inferensi Korelasi Silang Parsial	119
III. Pemodelan <i>Inflow</i> Tahap Kedua Menggunakan <i>Hybrid</i> GSTAR-FFNN	123
IV. Pemodelan <i>Inflow</i> Tahap Kedua Menggunakan <i>Hybrid</i> GSTAR-DLNN	128

4.2.4 Model Terbaik <i>Inflow</i> Uang Kartal di KPw BI Wilayah Jawa Timur	133
4.2.5 Pemodelan <i>Outflow</i> Tahap Pertama	136
4.2.6 Pemodelan <i>Outflow</i> Tahap Kedua	139
I. Pemodelan <i>Outflow</i> Tahap Kedua Menggunakan VAR	139
II. Pemodelan <i>Outflow</i> Tahap Kedua Menggunakan GSTAR	144
a. Bobot Seragam	144
b. Bobot Invers Jarak	146
c. Bobot Normalisasi Inferensi Korelasi Silang Parsial	148
III. Pemodelan <i>Outflow</i> Tahap Kedua Menggunakan <i>Hybrid</i> GSTAR-FFNN	152
IV. Pemodelan <i>Outflow</i> Tahap Kedua Menggunakan <i>Hybrid</i> GSTAR-DLNN	157
4.3 Perbandingan Akurasi Ramalan Data <i>Inflow</i> dan <i>Outflow</i> di KPw BI Wilayah Jawa Timur dengan Penelitian Sebelumnya	164
BAB 5 KESIMPULAN DAN SARAN	
5.1 Kesimpulan	165
5.2 Saran	165
DAFTAR PUSTAKA	167
LAMPIRAN	175
BIOGRAFI PENULIS	287

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Contoh Plot MCCF untuk Tiga Variabel <i>Time Series</i>	14
Gambar 2.2 Contoh Plot MPCCF untuk Tiga Variabel <i>Time Series</i>	17
Gambar 2.3 Peta Lokasi dan Wilayah Kerja KPw BI Wilayah Jawa Timur	25
Gambar 2.4 Contoh Arsitektur FFNN.....	37
Gambar 2.5 Fungsi <i>Hyperbolic Tangent</i>	37
Gambar 3.1 Tahapan Pembentukan Model GSTARX.....	51
Gambar 3.2 <i>Flowchart</i> Pemodelan <i>Hybrid</i> GSTARX-FFNN	53
Gambar 3.3 <i>Flowchart</i> Pemodelan <i>Hybrid</i> GSTARX-DLNN	53
Gambar 4.1 Plot Komponen (a) Tren dan (b) Musiman	55
Gambar 4.2 Plot Komponen Variasi Kalender	56
Gambar 4.3 Matriks Plot Deret <i>Noise</i> Linier di Tiga Lokasi	57
Gambar 4.4 Plot <i>Time Series</i> Data Simulasi 1 di Tiga Lokasi	58
Gambar 4.5 <i>Time Series Plot</i> Residual Tahap Pertama Data Simulasi 1 Skenario I	62
Gambar 4.6 Representasi Skematik MCCF Residual Data Simulasi 1 Skenario I	62
Gambar 4.7 Representasi Skematik MPCCF Residual Data Simulasi 1 Skenario I	62
Gambar 4.8 <i>Time Series Plot</i> Data Aktual dan Ramalan <i>Full Model</i> VARX(1) Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3	65
Gambar 4.9 Koefisien Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Model GSTAR setiap Replikasi Data Simulasi (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3	67
Gambar 4.10 <i>Time Series Plot</i> Data Aktual dan Ramalan GSTARX Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3	69
Gambar 4.11 Arsitektur GSTAR-FFNN dengan 6 <i>Input</i> dan 1 <i>Hidden</i> <i>Layer</i>	70

Gambar 4.12	<i>Time Series Plot</i> Data Aktual dan Ramalan <i>Hybrid</i> GSTARX-FFNN Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3	71
Gambar 4.13	<i>Line Plot</i> Pengaruh Jumlah <i>Neuron</i> Terhadap Nilai RMSE, <i>In Sample</i> (kiri) dan <i>Out Sample</i> (kanan), Model <i>Hybrid</i> GSTARX-FFNN	72
Gambar 4.14	Arsitektur GSTAR-ANN dengan 6 <i>Input</i> dan 2 <i>Hidden Layer</i>	74
Gambar 4.15	<i>Time Series Plot</i> Data Aktual dan Ramalan <i>Hybrid</i> GSTARX-DLNN Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3	76
Gambar 4.16	<i>Line Plot</i> Pengaruh Jumlah <i>Neuron</i> Terhadap Nilai RMSE, <i>In Sample</i> (kiri) dan <i>Out Sample</i> (kanan), Model <i>Hybrid</i> GSTARX-DLNN	77
Gambar 4.17	<i>Line Plot</i> Pengaruh Jumlah <i>Hidden Layer</i> Terhadap Nilai RMSE, <i>In Sample</i> (kiri) dan <i>Out Sample</i> (kanan) Model <i>Hybrid</i> GSTARX-ANN	77
Gambar 4.18	<i>Line Plot</i> Nilai RMSE Skenario I di Tiga Lokasi, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3	79
Gambar 4.19	<i>Box Plot</i> Nilai RMSE di Tiga Lokasi pada Skenario I	80
Gambar 4.20	Model Terbaik Data Simulasi Skenario I	80
Gambar 4.21	Matriks Plot Deret <i>Noise</i> Nonlinier di Tiga Lokasi	82
Gambar 4.22	Matriks Plot Residual Tahap Pertama Data Simulasi 1 Skenario II	85
Gambar 4.23	Plot <i>Time Series</i> Residual Tahap Pertama	86
Gambar 4.24	Representasi Skematik MCCF Residual Data Simulasi 1	86
Gambar 4.25	Representasi Skematik MPCCF Residual Data Simulasi 1	86
Gambar 4.26	<i>Time Series Plot</i> Data Ramalan Model VARX(2) Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3	89
Gambar 4.27	<i>Time Series Plot</i> Data Aktual dan Ramalan GSTARX(2 ₁) Data Simulasi 1	91

Gambar 4.28	Arsitektur GSTAR-FFNN dengan 12 <i>Input</i> dan 1 <i>Hidden Layer</i>	92
Gambar 4.29	<i>Time Series Plot</i> Data Aktual dan Ramalan Simulasi 1 <i>Hybrid</i> GSTARX-FFNN	94
Gambar 4.30	Arsitektur GSTAR-DLNN dengan 12 <i>Input</i> dan 1 <i>Hidden Layer</i>	95
Gambar 4.31	<i>Time Series Plot</i> Data Aktual dan Ramalan Simulasi 1 <i>Hybrid</i> GSTARX-DLNN	97
Gambar 4.32	<i>Box Plot</i> Nilai RMSE di Tiga Lokasi pada Skenario II	98
Gambar 4.33	<i>Line Plot</i> Nilai RMSE <i>Out Sample</i> Skenario II di Tiga Lokasi	99
Gambar 4.34	Model Terbaik Data Simulasi Skenario II	99
Gambar 4.35	<i>Plot Time Series</i> Data <i>Inflow</i> (kiri) dan <i>Outflow</i> (kanan) di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember	101
Gambar 4.36	Pengaruh Minggu Terhadap Rata-rata <i>Inflow</i> Uang Kartal Saat dan Satu Bulan Setelah Hari Raya Idul Fitri di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember	103
Gambar 4.37	Pengaruh Minggu Terhadap Rata-rata <i>Outflow</i> Uang Kartal Saat dan Satu Bulan Sebelum Hari Raya Idul Fitri di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember	104
Gambar 4.38	Matriks <i>Plot Data</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i>	105
Gambar 4.39	<i>Time Series Plot</i> Residual Tahap I Data <i>Inflow</i> di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember	110
Gambar 4.40	Representasi Skema MCCF untuk Residual Data <i>Inflow</i>	110
Gambar 4.41	Representasi Skematik MPCCF Residual Data <i>Inflow</i>	111
Gambar 4.42	Perbandingan Data Aktual dan Ramalan Model VARX KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember	114
Gambar 4.43	Sekmatik Korelasi Silang Parsial antar Lokasi Residual <i>Inflow</i>	119
Gambar 4.44	Perbandingan Data Aktual dan Ramalan Model GSTARX	122

Gambar 4.45	Arsitektur Model <i>Hybrid</i> GSTAR-FFNN dengan 8 Variabel <i>Input</i>	124
Gambar 4.46	Arsitektur GSTAR-FFNN(8,2,1) Bobot Invers Jarak	126
Gambar 4.47	Perbandingan Data Aktual dan Ramalan Model GSTARX-FFNN	127
Gambar 4.48	Arsitektur Model <i>Hybrid</i> GSTAR-DLNN dengan 8 Variabel <i>Input</i>	128
Gambar 4.49	Arsitektur GSTAR-DLNN(8,15,4,1) Bobot Invers Jarak	130
Gambar 4.50	Perbandingan Data Aktual dan Ramalan Model GSTARX-DLNN	132
Gambar 4.51	Nilai RMSE <i>Out Sample k-Step Inflow</i> di KPw BI Jawa Timur	134
Gambar 4.52	<i>Time Series Plot</i> Residual Tahap I Data <i>Outflow</i> di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember	139
Gambar 4.53	Representasi Skema MCCF untuk Residual Data <i>Outflow</i>	140
Gambar 4.54	Representasi Skematik MPCCF Residual Data <i>Outflow</i>	140
Gambar 4.55	Perbandingan Data <i>Outflow</i> Aktual dan Ramalan Model VARX	143
Gambar 4.56	Sekmatik Korelasi Silang Parsial antar Lokasi Residual <i>Outflow</i>	148
Gambar 4.57	Perbandingan Data <i>Outflow</i> Aktual dan Ramalan Model GSTARX	151
Gambar 4.58	Arsitektur GSTAR-FFNN Bobot Invers Jarak Pemodelan Residual Tahap I Data <i>Outflow</i>	155
Gambar 4.59	Perbandingan Data <i>Outflow</i> Aktual dan Ramalan Model GSTARX-FFNN	156
Gambar 4.60	Arsitektur GSTAR-DLNN Bobot NIKSP Residual Tahap I Data <i>Outflow</i>	158
Gambar 4.61	Perbandingan Data <i>Outflow</i> Aktual dan Ramalan Model GSTARX-DLNN	160
Gambar 4.62	Nilai RMSE <i>Out Sample k-Step Outflow</i> di KPw BI Jawa Timur	163

DAFTAR TABEL

	Halaman
Tabel 2.1 Contoh Nilai MCCF untuk Tiga Variabel <i>Time Series</i>	14
Tabel 2.2 Contoh Nilai MPCCF untuk Tiga Variabel <i>Time Series</i>	17
Tabel 2.3 Jarak antar KPw Bank Indonesia Wilayah Jawa Timur (km)	26
Tabel 3.1 Tanggal Hari Raya Idul Fitri	47
Tabel 3.2 Struktur Data <i>Inflow</i> Metode GSTARX	47
Tabel 3.3 Struktur Data <i>Outflow</i> Metode GSTARX	48
Tabel 3.4 Syntax SAS Pemodelan VARX dan GSTARX	54
Tabel 4.1 Koefisien Parameter Tahap I pada Data Simulasi 1	58
Tabel 4.2 Nilai AIC Model VAR Residual Simulasi 1 Skenario I	63
Tabel 4.3 Estimasi Parameter <i>Full Model</i> VAR(1)	63
Tabel 4.4 Estimasi Parameter Model VAR(1) Setelah Di- <i>restrict</i>	64
Tabel 4.6 Koefisien Parameter Tahap Dua Model GSTAR Simulasi 1	67
Tabel 4.7 Nilai Kebaikan Model GSTARX pada Skenario I	70
Tabel 4.8 Nilai Kebaikan Model <i>hybrid</i> GSTARX-FFNN Data Simulasi 1 Skenario I	71
Tabel 4.9 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-FFNN pada Skenario I	73
Tabel 4.10 Nilai Kebaikan Model <i>hybrid</i> GSTARX-DLNN Data Simulasi 1 Skenario I	74
Tabel 4.11 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-DLNN pada Skenario I ...	76
Tabel 4.12 Estimasi Parameter Tahap I pada Data Simulasi 1 Skenario II	82
Tabel 4.13 Nilai AIC Model VAR Residual Skenario II Simulasi 1	87
Tabel 4.14 Estimasi Parameter VAR(2)	87
Tabel 4.15 Nilai Kebaikan Model VARX pada Skenario II	88
Tabel 4.16 Koefisien Parameter Tahap Dua Model GSTAR(2 ₁) Simulasi 1	90
Tabel 4.17 Nilai Kebaikan Model GSTARX pada Skenario II	92
Tabel 4.18 Nilai Kebaikan Model <i>hybrid</i> GSTARX-FFNN Data Simulasi 1 Skenario II	93
Tabel 4.19 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-FFNN pada Skenario II ...	94
Tabel 4.20 Nilai Kebaikan Model <i>Hybrid</i> GSTARX-DLNN pada Skenario II ..	96

Tabel 4.21	Statistika Deskriptif (miliar Rp) Data <i>Inflow</i> dan <i>Outflow</i> di KPw BI Jawa Timur	100
Tabel 4.22	Hasil Uji Terasvirta Data <i>Inflow Outflow</i> Terhadap Periode Waktu (<i>t</i>)	105
Tabel 4.23	Estimasi Parameter Tahap I <i>Inflow</i> di KPw BI Jawa Timur	106
Tabel 4.24	Nilai AIC Model VAR Residual Data <i>Inflow</i>	111
Tabel 4.25	Estimasi Parameter <i>Full Model</i> VAR(1) <i>Inflow</i>	112
Tabel 4.26	Nilai AIC Residual Model VAR Data <i>Inflow</i>	113
Tabel 4.27	Nilai Kebaikan Model VARX(1) Data <i>Inflow</i>	113
Tabel 4.28	Estimasi Parameter Bobot Seragam Residual <i>Inflow</i>	116
Tabel 4.29	Nilai AIC Residual Model GSTAR Bobot Seragam Data <i>Inflow</i>	117
Tabel 4.30	Estimasi Parameter Bobot Inversss Jarak Residual <i>Inflow</i>	118
Tabel 4.31	Nilai AIC Residual Model GSTAR Bobot Invers jarak Data <i>Inflow</i>	119
Tabel 4.32	Taksiran Normalisasi Inferensi Korelasi Silang Parsial antar Lokasi	119
Tabel 4.33	Estimasi Parameter Bobot NIKSP Residual <i>Inflow</i>	120
Tabel 4.34	Nilai AIC Residual Model GSTAR Bobot NIKSP Data <i>Inflow</i>	121
Tabel 4.35	Perbandingan Kebaikan Model GSTARX Masing-masing Bobot ...	122
Tabel 4.36	Nilai Kebaikan Model <i>hybrid</i> GSTARX-FFNN Data <i>Inflow</i>	125
Tabel 4.37	Nilai Kebaikan Model <i>hybrid</i> GSTARX-DLNN Data <i>Inflow</i>	129
Tabel 4.38	Kriteria Kebaikan Model Data <i>Inflow</i>	133
Tabel 4.39	Persentase Penurunan Nilai RMSE Terhadap Model <i>Hybrid</i> GSTARX-FFNN Bobot Invers Jarak	134
Tabel 4.40	Estimasi Parameter Tahap I <i>Outflow</i> di KPw BI Jawa Timur	135
Tabel 4.41	Nilai AIC Model VAR Residual Data <i>Outflow</i>	140
Tabel 4.42	Estimasi Parameter <i>Full Model</i> VAR(1) <i>Outflow</i>	141
Tabel 4.43	Nilai AIC Residual Model VAR Data <i>Outflow</i>	142
Tabel 4.44	Nilai Kebaikan Model VARX(1) Data <i>Outflow</i>	143
Tabel 4.45	Estimasi Parameter Bobot Seragam Residual <i>Outflow</i>	145
Tabel 4.46	Nilai AIC Residual Model GSTAR Bobot Seragam Data <i>Outflow</i>	146

Tabel 4.47	Estimasi Parameter Bobot Inversss Jarak Residual <i>Outflow</i>	146
Tabel 4.48	Nilai AIC Residual Model GSTAR Bobot Invers Jarak Data <i>Outflow</i>	148
Tabel 4.49	Taksiran Normalisasi Inferensi Korelasi Silang Parsial antar Lokasi	148
Tabel 4.50	Estimasi Parameter Bobot NIKSP Residual <i>Outflow</i>	149
Tabel 4.51	Nilai AIC Residual Model GSTAR Bobot NIKSP Data <i>Outflow</i>	150
Tabel 4.52	Perbandingan Kebaikan Model GSTARX Masing-masing Bobot ...	151
Tabel 4.53	Nilai Kebaikan Model <i>hybrid</i> GSTARX-FFNN Data <i>Outflow</i>	153
Tabel 4.54	Nilai Kebaikan Model <i>hybrid</i> GSTARX-DLNN Data <i>Outflow</i>	157
Tabel 4.55	Kriteria Kebaikan Model Data <i>Outflow</i>	162
Tabel 4.56	Persentase Pengurangan Nilai RMSE Terhadap Model <i>Hybrid</i> GSTARX-FFNN Bobot Invers Jarak	162
Tabel 4.57	Perbandingan Akurasi Model dengan Penelitian Sebelumnya	164

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 1.....	175
Lampiran 2. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 2.....	178
Lampiran 3. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 3.....	181
Lampiran 4. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 4.....	184
Lampiran 5. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 5.....	187
Lampiran 6. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 6.....	190
Lampiran 7. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 7.....	193
Lampiran 8. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 8.....	196
Lampiran 9. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 9.....	199
Lampiran 10. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario I	
Data Simulasi 10.	202
Lampiran 11. Contoh Syntax SAS Model VARX(1) dan GSTARX(1 ₁)	
Bobot Seragam	205
Lampiran 12. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 2	
Skenario I.....	206
Lampiran 13. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 3	
Skenario I.....	208
Lampiran 14. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 4	
Skenario I.....	210

Lampiran 15. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 5	
Skenario I.....	212
Lampiran 16. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 6	
Skenario I.....	214
Lampiran 17. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 7	
Skenario I.....	216
Lampiran 18. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 8	
Skenario I.....	218
Lampiran 19. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 9	
Skenario I.....	220
Lampiran 20. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 10	
Skenario I.....	222
Lampiran 21. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 1	224
Lampiran 22. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 2.....	227
Lampiran 23. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 3	230
Lampiran 24. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 4.....	233
Lampiran 25. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 5	236
Lampiran 26. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 6.....	239
Lampiran 27. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 7	242
Lampiran 28. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 8.....	245
Lampiran 29. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 9	248
Lampiran 30. <i>Output</i> SAS Pemodelan VARX dan GSTARX Skenario II	
Data Simulasi 10.....	251

Lampiran 31. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 1	
Skenario II	254
Lampiran 32. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 2	
Skenario II	256
Lampiran 33. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 3	
Skenario II	258
Lampiran 34. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 4	
Skenario II	260
Lampiran 35. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 5	
Skenario II	262
Lampiran 36. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 6	
Skenario II	264
Lampiran 37. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 7	
Skenario II	266
Lampiran 38. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 8	
Skenario II	268
Lampiran 39. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 9	
Skenario II	270
Lampiran 40. Nilai RMSE Model <i>hybrid</i> GSTARX-ANN Simulasi 10	
Skenario II	272
Lampiran 41. Nilai RMSE Data <i>Inflow</i> Model <i>hybrid</i> GSTARX-FFNN	274
Lampiran 42. Estimasi Parameter Model <i>hybrid</i> GSTAR-FFNN (8,2,1)	
Bobot Invers Jarak Data <i>Inflow</i>	275
Lampiran 43. Nilai RMSE Data <i>Inflow</i> Model <i>hybrid</i> GSTARX-DLNN	
Bobot Seragam	276
Lampiran 44. Nilai RMSE Data <i>Inflow</i> Model <i>hybrid</i> GSTARX-DLNN	
Bobot Invers Jarak	277
Lampiran 45. Nilai RMSE Data <i>Inflow</i> Model <i>hybrid</i> GSTARX-DLNN	
Bobot NIKSP	278
Lampiran 46. Estimasi Parameter Model <i>hybrid</i> GSTAR-DLNN	
(8,15,4,1) Data <i>Inflow</i>	279
Lampiran 47. Nilai RMSE Data <i>Outflow</i> Model <i>hybrid</i> GSTARX-FFNN	280

Lampiran 48. Estimasi Parameter Model <i>hybrid</i> GSTAR-FFNN (8,15,1)	
Data <i>Outflow</i>	281
Lampiran 49. Nilai RMSE Data <i>Outflow</i> Model <i>hybrid</i> GSTARX-	
DLNN Bobot Seragam	282
Lampiran 50. Nilai RMSE Data <i>Outflow</i> Model <i>hybrid</i> GSTARX-	
DLNN Bobot Invers jarak	283
Lampiran 51. Nilai RMSE Data <i>Outflow</i> Model <i>hybrid</i> GSTARX-	
DLNN Bobot NIKSP	284
Lampiran 52. Estimasi Parameter Model <i>hybrid</i> GSTAR-DLNN	
(8,15,4,1) Data <i>Outflow</i>	285
Surat Pernyataan	286

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Deret waktu (*time series*) adalah urutan pengamatan yang dikumpulkan dari waktu ke waktu dengan periode waktu yang sama, misalnya dalam jam, harian, mingguan, bulanan, dan tahunan (Hyndman dan Athanasopoulos, 2014). Analisis data *time series* dapat dilakukan dengan pendekatan univariat maupun multivariat. Salah satu metode *time series* univariat adalah model *Autoregressive Integrated Moving Average* (ARIMA) yang dikembangkan oleh Box dan Jenkins (Box, Jenkins, dan Reinsel, 2008). Model ARIMA digunakan untuk memodelkan data *time series* univariat yang mengandung unsur tren dan musiman. Sedangkan salah satu model *time series* multivariat adalah *Vector Autoregressive Integrated Moving Average* (VARIMA) yang dikembangkan oleh Hannan (1970).

Model VARIMA merupakan perluasan dari model ARIMA yang dapat menjelaskan keterkaitan antar pengamatan pada variabel tertentu pada suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya, dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya. Penelitian yang berkaitan dengan model VARIMA diantaranya, Öller (1985) dengan studi kasus data ekonomi Finlandia didapatkan hasil bahwa model VARIMA lebih baik dibandingkan model *judgmental* ARIMA, Grubb (1992) meneliti tentang indeks harga tepung di tiga lokasi di Amerika Serikat, dan Yunus (2016) memodelkan kecepatan angin di wilayah geografis yang luas (Laut Utara dan wilayah laut Baltik).

Selain berdimensi waktu, *time series* juga bisa berdimensi ruang dan waktu atau *space time* (Wei, 2006). Model *space time* merupakan suatu model yang menggabungkan unsur dependensi waktu dan lokasi pada suatu data *time series* multivariat, sebagai contoh, tingkat polusi udara per jam di beberapa titik pengamatan dalam satu wilayah (Gulliver dan Briggs, 2005). Model *space time* pertama kali diperkenalkan oleh Cliff dan Ord (1975) dikenal dengan model *Space Time Autoregressive* (STAR) dan model *Space Time Autoregressive*

Moving Average (STARMA). Kemudian dikembangkan oleh Peifer dan Deutsch (1980a, 1980b, 1980c) dan Stoffer (1986).

Beberapa penelitian yang menggunakan model STAR diantaranya Epperson (1993) yang menerapkan model STAR pada frekuensi gen diantara populasi, sehingga memodelkan variasi genetik berdasarkan ruang dan waktu. Fok, Dijk, dan Franses (2005), memodelkan sektor manufaktur Amerika Serikat menggunakan model STAR multilevel. Kamarianakis dan Prastacos (2005) menerapkan model *space time* untuk menyelesaikan masalah arus lalu lintas. Cheng, dkk (2014) menggunakan model STAR untuk mendeskripsikan autokorelasi dalam data jaringan dengan matriks bobot spasial dinamis.

Model STAR mempunyai kelemahan yaitu mengandung suatu parameter yang sama untuk menjelaskan keterkaitan pada lokasi dan waktu yang berbeda. Kenyataannya lebih sering ditemukan fenomena lokasi dengan sifat heterogen. Ruchjana (2002) mengembangkan suatu model yang mengatasi masalah tersebut, dikenal dengan nama model *Generalized Space Time Autoregressive* (GSTAR) dengan asumsi parameter model berubah untuk setiap lokasi.

Penelitian yang berkaitan dengan GSTAR pernah dilakukan oleh Borovkova, Lopuhaa, dan Ruchjana (2008) yang mengkaji sifat asimtotis dari parameter model GSTAR. Giacinto (2006) membentuk *subclass* dari model GSTARMA pada data tingkat pengangguran di Italia. Suhartono dan Subanar (2006) membahas dan mengembangkan penentuan bobot ruang (*space weight*) secara optimal pada model GSTAR dengan menerapkan inferensi statistik korelasi silang antar lokasi (*space*) pada jeda waktu yang sesuai. Wutsqa dan Suhartono (2010) mengaplikasikan model VAR-GSTAR pada data wisata mancanegara di Yogyakarta dan Bali.

Time series sering dipengaruhi oleh peristiwa eksternal tertentu seperti liburan, promosi penjualan, dan perubahan kebijakan lainnya (Wei, 2006). Model *time series* yang melibatkan variabel prediktor dikenal dengan istilah ARIMAX, dimana X merupakan notasi dari variabel prediktor yang dapat berskala metrik (interval atau rasio) atau nonmetrik (nominal atau ordinal). Model ARIMAX dengan X berupa skala metrik dikenal dengan istilah model Fungsi Transfer (Wei,

2006) sedangkan untuk X skala nonmetrik dikenal dengan istilah model Intervensi (Bowerman dan O'Connell, 1993) dan Model Variasi Kalender (Liu, 2006).

Dalam perkembangannya, penelitian tentang model *space time* yang mengandung variabel eksogen atau prediktor pernah dilakukan oleh Suhartono, Wahyuningrum, Setiawan, dan Akbar (2016), dengan variabel prediktor berskala nonmetrik yaitu kenaikan harga BBM dan libur lebaran. Suhartono, dkk (2016) menggunakan metode *Generalized Least Square* (GLS) untuk mengestimasi parameter model dikarenakan metode OLS mengasumsikan bahwa residual model memenuhi kondisi *white noise* dan berdistribusi normal. Hal ini berarti residual di lokasi tertentu tidak memiliki korelasi dengan residual di lokasi lain. Padahal residual model GSTAR dalam banyak kasus cenderung memiliki korelasi antar lokasi sehingga OLS menghasilkan estimator yang tidak efisien.

Menurut Zhang (2003), tidak menutup kemungkinan bahwa suatu data terbentuk dari struktur linier dan nonlinier sekaligus. Zhang (2003) kemudian mengenalkan suatu model *hybrid* dengan mengombinasikan ARIMA sebagai komponen linier dan ANN sebagai komponen nonlinier. Hasil penelitian Zhang menunjukkan bahwa model *hybrid* ARIMA-ANN dapat meningkatkan akurasi ramalan dibandingkan hasil ramalan model ARIMA dan ANN secara terpisah.

Model GSTAR memiliki keterbatasan yaitu tidak mampu memodelkan *time series* yang nonlinier. Hal ini bisa diatasi dengan menerapkan model *hybrid* pada GSTAR. Model *hybrid* bekerja dengan menggabungkan model linier dan nonlinier, sehingga dapat menangani struktur korelasi linier dan nonlinier. Beberapa model *time series* nonlinier telah dikembangkan oleh Tong (1990), Granger dan Teräsvirta (1993), serta Franses dan Dijk (2000). Salah satu model *time series* nonlinier yang dapat digunakan adalah Jaringan Syaraf Tiruan (*Artificial Neural Network*).

Artificial Neural Network (ANN) mengadopsi cara kerja syaraf biologis yang terdiri dari *neuron* sebagai pemrosesan input, kemudian nilai input yang ada akan dijumlahkan oleh suatu fungsi perambatan (*summing function*), dan memberikan output berdasarkan bobot yang ada. Model ANN banyak diaplikasikan dalam berbagai bidang *forecasting* seperti, harga saham (Haefke dan Helmenstein, 1996; Gencay dan Stengos, 1998; Qi dan Maddala, 1999), nilai

tukar (Kuan dan Liu, 1995; Franses dan Griensven, 1998; Gencay, 1999), dan suku bunga (Swanson dan White, 1995). Keuntungan menggunakan ANN adalah tidak perlu menentukan bentuk model tertentu karena modelnya dibentuk secara adaptif berdasarkan fitur yang disajikan dari data (Zhang dan Berardi, 1998).

Dalam model ANN diperlukan suatu arsitektur yang tepat untuk mendapatkan hasil ramalan yang menghasilkan kesalahan minimum. Secara intuisi arsitektur yang lebih dalam akan menghasilkan ramalan yang lebih baik. Hal ini sesuai dengan kajian teoritis yang diulas oleh Bengio, Lamblin, Popovici, dan Larochelle (2007) bahwa arsitektur yang lebih dalam mungkin diperlukan dalam mempelajari fungsi rumit yang dapat mewakili abstraksi tingkat tinggi. Kedalaman model ANN diukur dari jumlah *hidden layer*, jumlah *hidden layer* yang lebih dari satu dikenal dengan model *deep learning neural network* (DLNN).

Studi kasus yang digunakan pada penelitian ini adalah data *inflow* dan *outflow* di Bank Indonesia wilayah Jawa Timur yang mencakup empat Kantor Perwakilan (KPw), yaitu Surabaya, Malang, Kediri, dan Jember dimana ada kemungkinan bahwa *inflow* dan *outflow* di empat kota tersebut saling berkaitan. *Inflow* merupakan transaksi penyetoran uang dari perbankan ke Bank Indonesia, sedangkan *outflow* merupakan transaksi penarikan uang rupiah yang masih layak edar dari Bank Indonesia kepada perbankan (Bank Indonesia, 2013). Dipilihnya provinsi Jawa Timur dikarenakan pertumbuhan ekonomi di Jawa Timur selama dua tahun terakhir (sampai dengan triwulan II tahun 2017) selalu di atas rata-rata pertumbuhan ekonomi nasional yang menyebabkan tingginya angka *inflow* dan *outflow* di Bank Indonesia wilayah Jawa Timur. Kegiatan *inflow* dan *outflow* dilakukan untuk memenuhi ketersediaan uang yang beredar di masyarakat.

Indonesia sebagai negara dengan mayoritas penduduk Muslim menyebabkan banyak data ekonomi memiliki pola musiman yang dipengaruhi oleh dua jenis kalender, yaitu kalender Masehi dan kalender Islam. Efek kalender Masehi menyebabkan *inflow* dan *outflow* tinggi atau rendah pada bulan tertentu, sementara kalender Islam memengaruhi *inflow* dan *outflow* pada bulan sekitar Hari Raya Idul Fitri. Efek lebaran Idul Fitri tidak dapat diidentifikasi sebagai efek musiman karena lebaran Idul Fitri terjadi pada berbagai tanggal dan bulan dalam kalender Masehi dari tahun ke tahun. Sehingga perlu ditambahkan variabel

prediktor pada model GSTAR (kemudian dikenal dengan model GSTARX) yaitu, efek variasi kalender Hari Raya Idul Fitri. Wulansari, dkk (2014) pernah meneliti *netflow* uang kartal dengan memasukkan hari raya Idul Fitri sebagai efek variasi kalender terbukti dapat meningkatkan akurasi ramalan.

Pemodelan menggunakan data *inflow* dan *outflow* juga pernah dilakukan oleh Apriliadara, Suhartono, dan Prastyo (2016); Prayoga, Suhartono, dan Rahayu (2017a, 2017b), pemodelan data *inflow* dan *outflow* menggunakan model *space time* pernah dilakukan oleh Mubarak (2015). Penelitian yang dilakukan oleh Prayoga (2016) menunjukkan bahwa data *inflow* dan *outflow* di seluruh KPw Bank Indonesia mengandung komponen linier dan nonlinier sekaligus, sehingga memungkinkan untuk menggunakan model *hybrid*.

Sampai saat ini, belum ada pemodelan data *inflow* dan *outflow* dengan menggunakan model *space time* yang melibatkan variabel prediktor dengan mengombinasikan komponen linier dan nonlinier. Oleh karena itu, dikembangkan model *hybrid* GSTARX-ANN, dengan GSTARX sebagai komponen linier yang melibatkan variabel prediktor, dan ANN sebagai komponen nonlinier. Untuk mengetahui apakah kedalaman arsitektur memberikan hasil ramalan yang lebih baik maka pada penelitian ini jumlah *hidden layer* yang digunakan adalah satu *hidden layer* dikenal dengan model *hybrid* GSTARX *feed-forward neural network* (GSTARX-FFNN) dan dua *hidden layer* yaitu model *hybrid* GSTARX *deep learning neural network* (GSTARX-DLNN). Pemodelan menggunakan *hybrid* GSTARX-ANN akan dibandingkan dengan penelitian *inflow* dan *outflow* di Bank Indonesia wilayah Jawa Timur yang sudah pernah dilakukan sebelumnya. Model *hybrid* GSTARX-ANN dengan efek variasi kalender diharapkan dapat memberikan hasil ramalan yang lebih akurat.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah yang dibahas dalam penelitian ini adalah bagaimana kebaikan model *hybrid* GSTARX-ANN dalam menangkap pola data yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* yang linier maupun nonlinier. Bagaimana membentuk model peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia

wilayah Jawa Timur dengan menggunakan metode GSTARX dan *hybrid* GSTARX-ANN. Model apakah yang menjadi model terbaik dalam meramalkan data *inflow* dan *outflow* uang kartal di Bank Indonesia wilayah Jawa Timur.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, tujuan yang ingin dicapai dalam penelitian ini adalah

1. Mendapatkan hasil kajian simulasi untuk mengetahui kebaikan model *hybrid* GSTARX-ANN.
2. Mendapatkan model GSTARX dan *hybrid* GSTARX-ANN dalam peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia wilayah Jawa Timur.
3. Mendapatkan hasil dan membandingkan akurasi ramalan menggunakan model GSTARX dan *hybrid* GSTARX-ANN pada data *inflow* dan *outflow* uang kartal di Bank Indonesia wilayah Jawa Timur.

1.4 Manfaat Penelitian

Hasil penelitian ini diharapkan dapat menambah wawasan keilmuan dan pengetahuan dalam bidang statistika, khususnya dalam pemodelan *space time* dengan menerapkan model *hybrid* GSTARX-ANN yang memiliki akurasi tinggi namun masih bisa menjelaskan efek variasi kalender hari raya Idul Fitri. Penelitian ini diharapkan memperoleh ramalan yang sesuai untuk data *inflow* dan *outflow* uang kartal di KPw Bank Indonesia Surabaya, Malang, Kediri, dan Jember untuk beberapa periode ke depan, sebagai gambaran untuk Bank Indonesia di wilayah Jawa Timur dalam mendistribusikan uang kartal ke masing-masing kantor perwakilan wilayah di Jawa Timur.

1.5 Batasan Masalah

Ada beberapa batasan masalah dalam penelitian ini, diantaranya

1. Analisis data *inflow* dan *outflow* uang kartal hanya dilakukan pada Bank Indonesia wilayah Jawa Timur yang mencakup empat KPw, yaitu Surabaya, Malang, Kediri, dan Jember.

2. Variabel prediktor yang digunakan pada model GSTARX berskala nonmetrik yaitu efek variasi kalender Hari Raya Idul Fitri.
3. Estimasi parameter model GSTARX menggunakan *generalized least square* (GLS) dikarenakan residual model cenderung memiliki korelasi antar lokasi, sehingga OLS menghasilkan estimator yang tidak efisien.
4. Orde spasial yang digunakan adalah orde satu karena wilayah kerja masing-masing KPw Bank Indonesia wilayah Jawa Timur berdekatan secara langsung.
5. Dalam pemodelan *hybrid* GSTARX-ANN, jumlah neuron yang digunakan pada *hidden layer* pertama yaitu 1, 2, 3, 4, 5, 10, dan 15 sedangkan jumlah *neuron* pada *hidden layer* kedua adalah 1, 2, 3, 4, dan 5.

Halaman ini sengaja dikosongkan

BAB 2

TINJAUAN PUSTAKA

Tinjauan pustaka mendukung penyelesaian masalah dalam penelitian ini. Beberapa hal yang dibahas pada bab ini adalah model ARIMA, *time series* multivariat, model VAR, model STAR, model GSTAR, model *Artificial Neural Network* (ANN), model variasi kalender, dan model *hybrid* GSTARX-ANN.

2.1 Model ARIMA

Model ARIMA merupakan model *time series* univariat yang termasuk dalam kelompok model linier dan digunakan pada data yang memiliki pola tren, musiman, ataupun nonmusiman. Model ARIMA terdiri dari (Wei, 2006)

1. Model *Autoregressive* (AR)

Model *Autoregressive* (AR) merepresentasikan sebuah proses Z_t yang berhubungan dengan nilai Z pada waktu t sebelumnya (Z_{t-k}) ditambah sebuah nilai residual (a_t). Model AR adalah sebagai berikut

$$\begin{aligned}\dot{Z}_t &= \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t \\ \phi_p(B) \dot{Z}_t &= a_t,\end{aligned}\tag{2.1}$$

dengan $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ dan $\dot{Z}_t = Z_t - \mu$, a_t adalah residual yang sudah memenuhi asumsi *white noise* yaitu $E(a_t) = 0$ dan $Var(a_t) = \sigma_a^2$.

2. Model *Moving Average* (MA)

Moving Average (MA) merepresentasikan sebuah proses Z_t dengan nilai residual a_t pada waktu t sebelumnya. Model MA adalah sebagai berikut

$$\begin{aligned}\dot{Z}_t &= a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \\ \dot{Z}_t &= \theta_q(B) a_t,\end{aligned}\tag{2.2}$$

dengan $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ dan a_t adalah sebuah residual yang sudah memenuhi asumsi *white noise*.

3. Model *Autoregressive Moving Average* (ARMA)

Model ARMA merupakan gabungan dari model AR dan MA, dengan persamaan model sebagai berikut

$$\begin{aligned}\dot{Z}_t &= \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \\ \phi_p(B) \dot{Z}_t &= \theta_q(B) a_t,\end{aligned}\quad (2.3)$$

dengan $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ dan $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$,

a_t adalah sebuah residual yang sudah memenuhi asumsi *white noise*.

4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Time series yang tidak stasioner bisa dijadikan stasioner dengan melakukan *differencing*, model persamaan umum dari model ARIMA (p, d, q) adalah sebagai berikut

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B) a_t, \quad (2.4)$$

dengan

(p, d, q) : orde AR (p) , orde *differencing* (d) , orde MA (q) untuk pola nonmusiman,

$\phi_p(B)$: koefisien komponen AR nonmusiman dengan derajat p , dengan penjabaran sebagai berikut $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$,

$\theta_q(B)$: koefisien komponen MA nonmusiman dengan derajat q , dengan penjabaran sebagai berikut $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$,

a_t : nilai residual pada waktu ke- t yang sudah memenuhi asumsi *white noise*.

5. Model *Autoregressive Integrated Moving Average* (ARIMA) Musiman

Model ARIMA musiman merupakan model ARIMA yang mempunyai efek musiman pada waktu ke- s dengan notasi ARIMA $(P, D, Q)^s$. Bentuk umum model ARIMA multiplikatif musiman sebagai berikut

$$\Phi_P(B^s) \phi_p(B) (1-B)^d (1-B^s)^D \dot{Z}_t = \theta_q(B) \Theta_Q(B^s) a_t, \quad (2.5)$$

dengan,

- (p, d, q) : orde AR (p), orde *differencing* (d), orde MA (q) untuk pola nonmusiman,
- $(P, D, Q)^s$: orde AR (P), orde *differencing* (D), orde MA (Q) untuk pola musiman
- $\phi_p(B)$: koefisien komponen AR nonmusiman dengan derajat p , dengan penjabaran sebagai berikut $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$,
- $\Phi_p(B^s)$: koefisien komponen AR musiman s dengan penjabaran sebagai berikut $\Phi_p(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{Ps})$,
- $\theta_q(B)$: koefisien komponen MA nonmusiman dengan derajat q , dengan penjabaran sebagai berikut $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$,
- $\Theta_Q(B^s)$: koefisien komponen MA musiman s dengan penjabaran sebagai berikut $\Theta_Q(B^s) = (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs})$,
- $(1-B)^d$: operator untuk *differencing* orde d ,
- $(1-B^s)^D$: operator untuk *differencing* musiman s orde D ,
- a_t : nilai residual pada waktu ke- t yang sudah memenuhi asumsi *white noise* atau $a_t \sim WN(0, \sigma_a^2)$.

Metode peramalan yang sering digunakan adalah model ARIMA Box-Jenkins, yang bertujuan untuk mendapatkan orde p dan q dari data. Tahapan prosedur ARIMA Box-Jenkins adalah identifikasi model, estimasi parameter, cek diagnostik, dan peramalan.

2.2 Time Series Multivariat

Analisis *time series* yang melibatkan lebih dari satu variabel disebut dengan analisis *time series* multivariat. Sama halnya dengan *time series* univariat, *time series* multivariat juga memperhatikan stasioneritas data yang dapat dilihat dari plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF). Plot MCCF yang turun secara lambat mengindikasikan bahwa data belum stasioner dalam rata-rata sehingga perlu

dilakukan *differencing*. Sedangkan stasioneritas dalam varians dilihat dari plot Box-Cox, jika data belum stasioner dilakukan transformasi (Wei, 2006).

2.2.1 Model *Vector Autoregressive Moving Average* (VARMA)

Model *Vector Autoregressive Moving Average* (VARMA) merupakan perluasan dari model ARMA yang diterapkan pada data *time series* multivariat sebagai metode peramalan kuantitatif. Model VARMA menjelaskan keterkaitan antar pengamatan pada variabel tertentu pada suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya, dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya.

Diberikan $z_i(t)$ dengan $t \in T$, $T = \{1, 2, \dots, T\}$ dan $i = \{1, 2, \dots, N\}$ yang merupakan indeks parameter waktu dan variabel yang terhitung dan terbatas, maka model VARMA secara umum dapat dinyatakan dalam persamaan sebagai berikut (Wei, 2006)

$$\Phi_p(B) \dot{\mathbf{Z}}(t) = \Theta_q(B) \mathbf{a}(t), \quad (2.6)$$

dengan $\dot{\mathbf{Z}}(t)$ adalah vektor *time series* multivariat yang terkoreksi nilai rata-ratanya, $\Phi_p(B)$ dan $\Theta_q(B)$ berturut-turut adalah suatu matriks *autoregressive*, AR(p) dan matriks *moving average*, MA(q).

Dalam analisis *time series* sering dijumpai data-data yang tidak stasioner. Model VARMA yang tidak stasioner dapat dinyatakan dalam bentuk persamaan sebagai berikut (Wei, 2006),

$$\Phi_p(B) \mathbf{D}(B) \mathbf{Z}(t) = \Theta_q(B) \mathbf{a}(t), \quad (2.7)$$

dengan $\mathbf{D}(B)$ merupakan operator *differencing* yang dinyatakan dengan

$$\mathbf{D}(B) = \text{diag} \left((1-B)^{d_1}, (1-B)^{d_2}, \dots, (1-B)^{d_i} \right). \quad (2.8)$$

Tahapan dalam pembentukan model VARIMA yaitu identifikasi, estimasi parameter, cek diagnostik, pemilihan model terbaik, dan peramalan.

a. Identifikasi Model

Dalam tahapan identifikasi model menggunakan plot *time series*, MCCF, dan MPCCF.

i. Matrix Cross Correlation Function (MCCF)

Jika terdapat sebuah vektor *time series* dengan observasi sebanyak n , yaitu $\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n$, maka persamaan matriks korelasi sampelnya adalah sebagai berikut (Wei, 2006),

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (2.9)$$

dengan $\hat{\rho}_{ij}(k)$ merupakan korelasi silang sampel untuk komponen *series* ke- i dan ke- j yang dinyatakan dalam persamaan berikut

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{\sqrt{\left(\sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{j,t} - \bar{Z}_j)^2 \right)}} \quad (2.10)$$

\bar{Z}_i dan \bar{Z}_j merupakan rata-rata sampel dari komponen *series* yang bersesuaian. Untuk stasioneritas vektor, Hannan (1970) dalam Wei (2006) menunjukkan bahwa $\hat{\rho}(k)$ adalah estimator yang konstan yang berdistribusi normal asimtotis. Bartlett (1966) dalam Wei (2006) telah menurunkan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Berdasarkan hipotesis bahwa dua data *time series* Z_i dan Z_j tidak berkorelasi, sehingga Bartlett menunjukkan persamaan sebagai berikut

$$\text{Var}[\hat{\rho}_{ij}(k)] \cong \frac{1}{n-k} \left[1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s) \right], \quad |k| > q. \quad (2.11)$$

Sehingga ketika Z_i dan Z_j merupakan deret yang *white noise* maka diperoleh

$$\text{Cov}[\hat{\rho}_{ij}(k), \hat{\rho}_{ij}(k+s)] \cong \frac{1}{n-k} \quad (2.12)$$

dan

$$\text{Var}[\hat{\rho}_{ij}(k)] \cong \frac{1}{n-k} \quad (2.13)$$

untuk ukuran sampel yang besar, $(n-k)$ dalam persamaan (2.13) seringkali digantikan dengan n .

Persamaan matriks korelasi sampel digunakan untuk menentukan orde MA, namun bentuk matriks dan grafik akan semakin kompleks seiring dengan

meningkatnya dimensi vektor. Tiao dan Box (1981) dalam Wei (2006) mengatasinya dengan memperkenalkan metode yang sesuai untuk meringkas penjelasan korelasi sampel, yaitu dengan menggunakan simbol (+), (-), dan (.) pada baris ke- i dan kolom ke- j dari matriks korelasi sampel. Simbol (+) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang lebih besar dari 2 kali estimasi *standard error* dan menunjukkan adanya hubungan korelasi positif, (-) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang kurang dari -2 kali estimasi *standard error* atau adanya hubungan korelasi negatif, sedangkan (.) menotasikan nilai yang berada di antara ± 2 kali estimasi *standard error* yang artinya tidak terdapat hubungan korelasi.

Tabel 2.1 Contoh Nilai MCCF untuk Tiga Variabel *Time Series*

<i>Lag</i>	0			1			2		
Variabel	z_1	z_2	z_3	z_1	z_2	z_3	z_1	z_2	z_3
z_1	1,00	0,38	0,17	0,33	0,30	0,24	0,07	0,06	-0,07
z_2	0,38	1,00	0,27	0,18	0,24	0,17	0,12	-0,04	0,11
z_3	0,17	0,27	1,00	0,19	0,25	0,29	0,13	0,16	0,19

Hasil perhitungan nilai-nilai MCCF dari tiga variabel *time series* dengan masing-masing *series* terdiri dari 100 observasi ditunjukkan pada Tabel 2.2. Nilai batas ± 2 kali estimasi *standard error* didapat dari perhitungan berikut

$$\begin{aligned}\pm 2 \times \text{SE}(\rho_{ij}(1)) &= \pm 2 \times \sqrt{\frac{1}{100-1}} \\ &= \pm 0,2\end{aligned}\tag{2.14}$$

Nilai-nilai MCCF pada Tabel 2.1 selanjutnya dinotasikan ke dalam bentuk simbol dengan batas $\pm 0,2$ yang ditampilkan dalam Gambar 2.1 sebagai berikut

Variable/ Lag	0	1	2
Z_1	++.	+++	..-
Z_2	+++	.+.	.-.
Z_3	.++	.++	...

Gambar 2.1 Contoh Plot MCCF untuk Tiga Variabel *Time Series*

ii. **Matrix Partial Cross Correlation Function (MPCCF)**

Fungsi autokorelasi parsial (PACF) digunakan untuk mengidentifikasi orde model AR dalam *time series* univariat. Tiao dan Box (1981) dalam Wei (2006) melakukan generalisasi konsep PACF ke dalam bentuk vektor *time series*, yang mendefinisikan matriks autoregresi parsial *lag s* sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses *vector autoregressive* orde *s*. Dalam regresi linier multivariat dinotasikan sebagai $\Phi_{s,s}$,

$$\mathbf{Z}_{t+s} = \Phi_{s,1}\mathbf{Z}_{t+s+1} + \Phi_{s,2}\mathbf{Z}_{t+s+2} + \dots + \Phi_{s,s}\mathbf{Z}_t + \mathbf{e}_{s,t+s}. \quad (2.15)$$

Heyse dan Wei (1985a, b) dalam Wei (2006) memperluas definisi parsial autokorelasi univariat menjadi vektor *time series* dan memperoleh matrik korelasi antara \mathbf{Z}_t dan \mathbf{Z}_{t+s} setelah menghilangkan dependensi linier dari masing-masing $\mathbf{Z}_{t+1}, \mathbf{Z}_{t+2}, \dots, \mathbf{Z}_{t+s-1}$. Matrik korelasi yang didefinisikan sebagai korelasi antar vektor *residual* memiliki persamaan sebagai berikut

$$\begin{aligned} \mathbf{u}_{s-1,t+s} &= \mathbf{Z}_{t+s} - \alpha_{s-1,1}\mathbf{Z}_{t+s-1} - \dots - \alpha_{s-1,s-1}\mathbf{Z}_{t+1} \\ &= \begin{cases} \mathbf{Z}_{t+s} - \sum_{k=1}^{s-1} \alpha_{s-1,k}\mathbf{Z}_{t+s-k}, & s \geq 2, \\ \mathbf{Z}_{t+1}, & s = 1, \end{cases} \end{aligned} \quad (2.16)$$

dan

$$\begin{aligned} \mathbf{v}_{s-1,t} &= \mathbf{Z}_t - \beta_{s-1,1}\mathbf{Z}_{t+1} - \dots - \beta_{s-1,s-1}\mathbf{Z}_{t+s-1} \\ &= \begin{cases} \mathbf{Z}_t - \sum_{k=1}^{s-1} \beta_{s-1,k}\mathbf{Z}_{t+k}, & s \geq 2, \\ \mathbf{Z}_t, & s = 1. \end{cases} \end{aligned} \quad (2.17)$$

Matriks koefisien regresi linier multivariat $\alpha_{s-1,k}$ dan $\beta_{s-1,k}$ diminimalisasi menjadi $E[\|\mathbf{u}_{s-1,t+s}\|^2]$ dan $E[\|\mathbf{v}_{s-1,t}\|^2]$. Minimum dari persamaan diatas untuk generalisasi multivariat didapat persamaan

$$\begin{aligned} \mathbf{A}(s)\boldsymbol{\alpha}'(s) &= \mathbf{c}(s) \\ \mathbf{A}(s)\boldsymbol{\beta}'(s) &= \mathbf{b}(s) \end{aligned} \quad (2.18)$$

$$\begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \cdots & \Gamma(0) \end{bmatrix} \begin{bmatrix} \alpha'_{s-1,1} \\ \alpha'_{s-1,2} \\ \vdots \\ \alpha'_{s-1,s-1} \end{bmatrix} = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix} \quad (2.19)$$

untuk $s \geq 2$, didapatkan nilai $\mathbf{A}(s)$, $\mathbf{b}(s)$, dan $\mathbf{c}(s)$ adalah sebagai berikut

$$\mathbf{A}(s) = \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \cdots & \Gamma(0) \end{bmatrix}, \mathbf{b}(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix},$$

$$\mathbf{c}(s) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix},$$

$$\alpha(s) = \begin{bmatrix} \alpha'_{s-1,1} \\ \alpha'_{s-1,2} \\ \vdots \\ \alpha'_{s-1,s-1} \end{bmatrix}, \beta'(s) = \begin{bmatrix} \beta'_{s-1,s-1} \\ \beta'_{s-1,s-2} \\ \vdots \\ \beta'_{s-1,1} \end{bmatrix},$$

sehingga $\text{var}(\mathbf{u}_{s-1,t+s})$ dapat ditulis sebagai $\mathbf{V}_u(s)$, $\text{var}(\mathbf{v}_{s-1,t})$ adalah $\mathbf{V}_v(s)$ dan $\text{cov}(\mathbf{v}_{s-1,t}, \mathbf{u}_{s-1,t+s})$ sebagai $\mathbf{V}_{vu}(s)$. Kemudian Heyse dan Wei (1985a, 1985b) dalam Wei (2006) mendapatkan persamaan untuk matriks autokorelasi lag parsial pada lag s sebagai berikut

$$\mathbf{P}(s) = [\mathbf{D}_v(s)]^{-1} \mathbf{V}_{vu}(s) [\mathbf{D}_u(s)]^{-1} \quad (2.20)$$

dengan $\mathbf{D}_v(s)$ adalah matrik diagonal dimana elemen ke- i merupakan akar dari elemen diagonal ke- i dari $\mathbf{V}_v(s)$, dan $\mathbf{D}_u(s)$ didefinisikan sama untuk $\mathbf{V}_u(s)$.

Tiao dan Box (1981) dalam Wei (2006) menotasikan elemen matriks $\hat{\mathbf{P}}_{ij}(s)$ dengan simbol (+), (-), dan (.). Simbol (+) untuk nilai $\hat{\mathbf{P}}_{ij}(s)$ lebih besar dari $2/\sqrt{n}$, simbol (-) untuk nilai $\hat{\mathbf{P}}_{ij}(s)$ kurang dari $-2/\sqrt{n}$, dan simbol (.) untuk nilai $\hat{\mathbf{P}}_{ij}(s)$ diantara $-2/\sqrt{n}$ dan $2/\sqrt{n}$. Berikut ini disajikan contoh nilai-nilai hasil perhitungan MPCCF dalam Tabel 2.2.

Tabel 2.2 Contoh Nilai MPCCF untuk Tiga Variabel *Time Series*

<i>Lag</i>	1			2			3		
Variabel	z_1	z_2	z_3	z_1	z_2	z_3	z_1	z_2	z_3
z_1	0,28	0,11	0,09	0,17	0,03	-0,11	-0,01	0,05	0,10
z_2	0,02	0,07	0,21	-0,05	0,04	-0,12	-0,06	0,04	0,11
z_3	0,25	0,09	0,22	-0,11	0,01	-0,16	-0,02	0,01	0,12

Dengan jumlah data 100 observasi didapatkan bentuk simbol dari nilai MPCCF pada Tabel 2.2 ditampilkan dalam Gambar 2.2.

Variable/ Lag	0	1	2
Z_1	+. .	. . -	- . .
Z_2	. . +	- . -	- . .
Z_3	+ . +	- . -	- . .

Gambar 2.2 Contoh Plot MPCCF untuk Tiga Variabel *Time Series*

b. Estimasi Parameter

Setelah melakukan identifikasi model dan mendapatkan model dugaan, langkah selanjutnya adalah melakukan estimasi parameter. Salah satu metode yang dapat digunakan untuk estimasi parameter adalah *Maximum Likelihood Estimation* (MLE). Estimasi parameter untuk kasus univariat dapat digeneralisasikan menjadi bentuk matriks $\Phi = (\Phi_1, \dots, \Phi_p)$, $\Theta = (\Theta_1, \dots, \Theta_q)$ dan Σ . Misalkan $Z = (Z_1, Z_2, \dots, Z_n)$ menyatakan suatu proses VARMA (p, q) maka fungsi *log-likelihood*-nya sebagai berikut (Wei, 2006),

$$\begin{aligned} \ln L(\Phi, \Theta, \Sigma | Z) &= -\frac{nm}{2} \ln(2\pi) - \frac{n}{2} \ln |\Sigma| - \frac{1}{2} \sum_{t=1}^n \mathbf{a}_t' \Sigma^{-1} \mathbf{a}_t \\ &= -\frac{nm}{2} \ln(2\pi) - \frac{n}{2} \ln |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1} S(\Phi, \Theta), \end{aligned} \quad (2.21)$$

dengan,

$$\mathbf{a}_t = Z_t - \Phi_1 Z_{t-1} - \dots - \Phi_p Z_{t-p} + \Theta_1 \mathbf{a}_{t-1} + \dots + \Theta_q \mathbf{a}_{t-q}, \quad (2.22)$$

dan

$$S(\Phi, \Theta) = \sum_{t=1}^n \mathbf{a}_t \mathbf{a}_t' \quad (2.23)$$

Misalkan pada model VAR(p), \mathbf{Z}_t menyatakan suatu proses m -variat VAR(p),

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \dots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t, \quad (2.24)$$

dengan $\mathbf{a}_t \sim i.i.d. N(\mathbf{0}, \Sigma)$, selanjutnya dengan metode *least square* yang meminimumkan jumlah kuadrat *error* diperoleh hasil persamaan untuk nilai estimasi parameter $\hat{\Phi}$ sebagai berikut

$$\hat{\Phi}' = \left[\sum_{t=1}^n \mathbf{Z}_t \mathbf{Y}_t' \right] \left[\sum_{t=1}^n \mathbf{Y}_t \mathbf{Y}_t' \right]^{-1}. \quad (2.25)$$

dengan \mathbf{Y}_t merupakan vektor berukuran $mp \times 1$ sebagai berikut

$$\mathbf{Y}_t = \begin{bmatrix} \mathbf{Z}_{t-1} \\ \mathbf{Z}_{t-2} \\ \vdots \\ \mathbf{Z}_{t-p} \end{bmatrix}. \quad (2.26)$$

Hasil penaksiran parameter selanjutnya masih perlu diuji untuk mengetahui signifikansi parameter terhadap model dengan menggunakan statistik uji t . Misalkan β merupakan suatu parameter pada model VARMA (mencakup Φ dan Θ) dan $\hat{\beta}$ merupakan taksiran dari β , maka pengujian signifikansi parameter dapat dinyatakan dengan hipotesis sebagai berikut

$H_0 : \beta_{ij} = 0$, dengan $i, j = 1, 2, \dots, N$ (semua parameter model tidak signifikan)

$H_1 : \text{minimal ada satu } \beta_{ij} \neq 0$, (minimal ada satu parameter yang signifikan).

Statistik uji yang digunakan adalah sebagai berikut $t = \frac{\hat{\beta}_{ij}}{SE(\hat{\beta}_{ij})}$. Hipotesis nol akan

ditolak jika $|t| > t_{\alpha/2; n-p}$ dengan $SE(\hat{\beta}_{ij})$ merupakan standar *error* dari nilai taksiran β dan p menunjukkan banyaknya parameter yang ditaksir.

c. Cek Diagnostik

Setelah memperoleh nilai estimasi parameter, selanjutnya kecukupan dari kesesuaian model harus diperiksa dengan analisis diagnostik dari residual,

$$\hat{\mathbf{a}}_t = \dot{\mathbf{Z}}_t - \hat{\Phi}_1 \dot{\mathbf{Z}}_{t-1} - \dots - \hat{\Phi}_p \dot{\mathbf{Z}}_{t-p} + \hat{\Theta}_1 \hat{\mathbf{a}}_{t-1} + \dots + \hat{\Theta}_q \hat{\mathbf{a}}_{t-q}, \quad (2.27)$$

dengan $\dot{\mathbf{Z}}_t$ digunakan untuk menotasikan $(\mathbf{Z}_t - \hat{\boldsymbol{\mu}})$. $\boldsymbol{\mu}$ merupakan vektor rata-rata, serta $\hat{\Phi}_i$ dan $\hat{\Theta}_i$ adalah nilai taksiran dari parameter Φ_i dan Θ_i . Suatu model *time series* dikatakan cukup jika residual model bersifat *white noise*. Maka dari itu, matriks korelasi dari $\hat{\mathbf{a}}_t$ nilainya harus sama dengan nol (Wei, 2006). Uji diagnostik yang digunakan adalah uji Portmanteau, yang diperkenalkan pertama kali oleh Box-Pierce (1970) dalam Pena dan Rodriguez (2002) dan digunakan untuk mengetahui signifikansi keseluruhan dari autokorelasi *residual* sampai lag- h . Uji ini dirancang untuk hipotesis sebagai berikut

$$H_0: \rho_1 = \dots = \rho_h = 0$$

$$H_1: \text{minimal ada satu } \rho_j \neq 0; \text{ dengan } j = 1, 2, \dots, h.$$

Statistik uji yang digunakan adalah sebagai berikut

$$Q = n \sum_{j=1}^h \rho_j^2. \quad (2.28)$$

Uji Portmanteau dalam perkembangannya menunjukkan bahwa pada sampel terbatas akan menghasilkan distribusi yang tidak mendekati distribusi *chi-squared*. Fakta ini yang menjadi titik awal dari beberapa modifikasi, salah satunya usulan perbaikan dari Ljung-Box (1987) dalam Pena dan Rodriguez (2002). Sehingga uji Portmanteau ini diperbaiki menjadi uji Portmanteau Ljung-Box dengan menggantikan koefisien autokorelasi *residual* (ρ_j) dengan nilai standarnya ($\hat{\rho}_j$). Sehingga, statistik ujinya menjadi seperti persamaan berikut

$$Q_{LB} = n(n+2) \sum_{j=1}^h (n-j)^{-1} \rho_j^2, \quad (2.29)$$

dengan $\hat{\rho}_j^2 = \frac{(n+2)}{(n-j)} \rho_j^2$. Statistik uji Portmanteau Ljung-Box akan menyebar mengikuti distribusi *chi-squared*, $\chi_{\alpha; (h-p-q)}^2$.

d. Pemilihan Model Terbaik

Pemilihan model terbaik digunakan untuk memilih suatu model terbaik berdasarkan residual yang dihasilkan. Akaike (1973) dalam Wei (2006) memperkenalkan *Akaike's Information Criterion* (AIC) yang merupakan suatu kriteria pemilihan model terbaik dengan mempertimbangkan banyaknya parameter dalam model. AIC digunakan untuk kriteria *in sample*, yang menyatakan model terbaik adalah model yang memiliki nilai AIC terendah. Nilai AIC diperoleh melalui persamaan sebagai berikut (Wei, 2006),

$$AIC(p) = \ln(|\mathbf{S}_p|) + \frac{2pm^2}{n}, \quad (2.30)$$

dengan n merupakan jumlah observasi, m adalah jumlah variabel, dan $|\mathbf{S}_p|$ adalah determinan dari *residual sum of square*,

$$\begin{aligned} \mathbf{S}_p = & \sum_{t=p+1}^n (\mathbf{Z}_t - \hat{\boldsymbol{\tau}} - \hat{\Phi}_1 \mathbf{Z}_{t-1} - \dots - \hat{\Phi}_p \mathbf{Z}_{t-p}) \\ & \times (\mathbf{Z}_t - \hat{\boldsymbol{\tau}} - \hat{\Phi}_1 \mathbf{Z}_{t-1} - \dots - \hat{\Phi}_p \mathbf{Z}_{t-p})' \end{aligned} \quad (2.31)$$

dengan $\hat{\boldsymbol{\tau}}$ merupakan vektor konstan.

Kriteria pemilihan model terbaik untuk data *out-sample* menggunakan nilai RMSE (*Root Mean Square Error*). Model terbaik dinyatakan dengan nilai RMSE terkecil. Nilai RMSE didapat dari persamaan sebagai berikut

$$MSE = \frac{1}{M} \sum_{l=1}^M (Z_{n+l} - \hat{Z}_n(l))^2 \quad (2.32)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{l=1}^M (Z_{n+l} - \hat{Z}_n(l))^2} \quad (2.33)$$

dengan M adalah banyaknya ramalan yang dilakukan.

e. Peramalan

Model VARIMA(p, q) pada lokasi ke- s dan dengan ramalan l tahap kedepan pada waktu awal yang sama, yaitu T adalah

$$\hat{\mathbf{Z}}_{i,T}(l) = \sum_{i=1}^p \mathbf{\Phi}_i \mathbf{Z}_{n+1-i} - \sum_{i=1}^q \mathbf{\Theta}_i \mathbf{a}_{n+1-i}, \quad (2.34)$$

dan *error* dari ramalan pada persamaan (2.34) sebagai berikut

$$\mathbf{a}_{i,T}(l) = \mathbf{Z}_{n+l} - \hat{\mathbf{Z}}_n(l). \quad (2.35)$$

Matriks varians-kovarians *error* peramalan adalah $\mathbf{\Omega}$. Jika \mathbf{Z}_t memiliki stasioneritas yang lemah, maka peramalan sebanyak l tahap ke depan atau $\hat{\mathbf{Z}}_{i,T}(l)$ akan konvergen menuju vektor rata-rata μ sebagai peningkatan ramalan pada waktu l .

2.2.2 Model *Space Time Autoregressive* (STAR)

Model *space-time* pertama kali diperkenalkan oleh Cliff dan Ord (1975) dikenal dengan model *Space Time Autoregressive* (STAR) dan model *Space Time Autoregressive Moving Average* (STARMA). Sama halnya dengan model VAR, model STAR mempunyai karakteristik dependensi linier dalam lokasi dan waktu.

Jika diberikan $\mathbf{Z}(t)$ adalah vektor berukuran $(N \times 1)$ dari pengamatan pada waktu ke- t , maka model STARMA dari Pfeiffer dan Deustch (1980a) adalah

$$\mathbf{Z}(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \mathbf{Z}(t-k) - \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} \mathbf{W}^{(l)} \mathbf{e}(t-k) + \mathbf{e}(t) \quad (2.36)$$

dengan,

- p : orde *autoregressive*,
- q : orde *moving average*,
- λ_k : orde spasial dari struktur *autoregressive* ke- k ,
- m_k : orde spasial dari struktur *moving average* ke- k ,
- ϕ_{kl} : parameter *autoregressive* pada lag waktu k dan lag spasial l ,
- θ_{kl} : parameter *moving average* pada lag waktu k dan lag spasial l ,
- $\mathbf{W}^{(l)}$: matriks bobot berukuran $(N \times N)$ pada orde spasial l ,
- $\mathbf{e}(t)$: vektor error pada waktu t yang berdistribusi normal multivariat, dengan

$$E[\mathbf{e}(t)] = 0, \quad E[\mathbf{e}(t)\mathbf{e}(t+s)'] = \begin{cases} \mathbf{G} & s = 0 \\ \mathbf{0} & s \neq 0 \end{cases}, \text{ dan}$$

$$E[\mathbf{Z}(t)\mathbf{e}(t+s)'] = \mathbf{0} \quad s > 0.$$

Model ini disebut sebagai model STARMA($p_{\lambda_1, \lambda_2, \dots, \lambda_p}, q_{m_1, m_2, \dots, m_q}$). Apabila orde $p = 0$, maka model (2.36) menjadi model *Space Time Moving Average* (STMA) dan jika orde $q = 0$ menjadi model *Space Time Autoregressive* (STAR).

Model STAR orde (p_1), yang berarti orde spasial adalah 1 dan orde waktu adalah p , atau bisa ditulis STAR (p_1) dari Pfeifer dan Deutsch (1980a) dirumuskan sebagai berikut

$$\mathbf{Z}(t) = \sum_{k=1}^p [\phi_{k0} \mathbf{W}^{(0)} \mathbf{Z}(t-k) + \phi_{k1} \mathbf{W}^{(1)} \mathbf{Z}(t-k)] + \mathbf{e}(t). \quad (2.37)$$

Model sederhana AR berorde 1 dan spasial lag 1 atau STAR (1_1), dengan empat lokasi ($N = 4$), dinyatakan sebagai berikut

$$\mathbf{Z}(t) = \phi_{10} \mathbf{I}_4 \mathbf{Z}(t-1) + \phi_{11} \mathbf{W}^{(1)} \mathbf{Z}(t-1) + \mathbf{e}(t) \quad (2.38)$$

dari model (2.38), untuk empat lokasi model di lokasi ke- N dapat dinyatakan sebagai berikut

$$\begin{aligned} Z_1(t) &= \phi_{10} Z_1(t-1) + \phi_{11} w_{12} Z_2(t-1) + \phi_{11} w_{13} Z_3(t-1) + \phi_{11} w_{14} Z_4(t-1) + e_1(t) \\ Z_2(t) &= \phi_{10} Z_2(t-1) + \phi_{11} w_{21} Z_1(t-1) + \phi_{11} w_{23} Z_3(t-1) + \phi_{11} w_{24} Z_4(t-1) + e_2(t) \\ Z_3(t) &= \phi_{10} Z_3(t-1) + \phi_{11} w_{31} Z_1(t-1) + \phi_{11} w_{32} Z_2(t-1) + \phi_{11} w_{34} Z_4(t-1) + e_3(t) \\ Z_4(t) &= \phi_{10} Z_4(t-1) + \phi_{11} w_{41} Z_1(t-1) + \phi_{11} w_{42} Z_2(t-1) + \phi_{11} w_{43} Z_3(t-1) + e_4(t). \end{aligned} \quad (2.39)$$

Berdasarkan model pada persamaan (2.39), terdapat parameter yang sama untuk menjelaskan keterkaitan pada lokasi dan waktu yang berbeda, kenyataannya lebih sering ditemukan fenomena lokasi dengan sifat heterogen. Kemudian Ruchjana (2002) mengembangkan model yang mengatasi masalah tersebut dimana parameter model berubah untuk tiap lokasi, dikenal dengan model *Generalized Space-Time Autoregressive* (GSTAR).

2.2.3 Model Generalized Space Time Autoregressive (GSTAR)

Model *Generalized Space Time Autoregressive* (GSTAR) merupakan suatu model yang dapat mengatasi asumsi yang menyatakan lokasi-lokasi penelitian yang bersifat heterogen, sehingga parameter untuk setiap lokasi berbeda. Berbeda dengan model STAR yang hanya dapat digunakan jika lokasi penelitian bersifat homogen, hal ini menyebabkan model GSTAR lebih fleksibel dari model STAR yang juga merupakan spesifikasi dari model VAR (Borovkova, Lopuhaa, dan Ruchjana, 2002).

Jika diberikan sebuah deret $\{\mathbf{Z}(t) : t = 0, \pm 1, \pm 2, \dots, T\}$ yang merupakan sebuah deret waktu multivariat dari N komponen, maka model GSTAR dengan orde *autoregressive* p dan orde spasial $\lambda_1, \lambda_2, \dots, \lambda_p$, atau disebut sebagai GSTAR $(p; \lambda_1, \lambda_2, \dots, \lambda_p)$ dalam notasi matriks dapat ditulis sebagai berikut (Wutsqa, Suhartono, dan Sutijo, 2010)

$$\mathbf{Z}(t) = \sum_{k=1}^p \left(\Phi_{k0} + \sum_{l=1}^{\lambda_k} \Phi_{kl} \mathbf{W}^{(l)} \right) \mathbf{Z}(t-k) + \mathbf{e}(t) \quad (2.40)$$

dengan $\Phi_{k0} = \text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^N)$, $\Phi_{kl} = \text{diag}(\phi_{kl}^1, \dots, \phi_{kl}^N)$, $\mathbf{e}(t)$ merupakan vektor *noise* berukuran $(N \times 1)$ yang independen, identik, berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarians $\sigma^2 \mathbf{I}_N$, dan nilai pembobot yang dipilih memenuhi syarat $w_{ii}^{(l)} = 0$ dan $\sum_{j \neq i} w_{ij}^{(l)} = 1$.

Sebagai contoh persamaan model GSTAR untuk orde waktu dan orde spasial satu, GSTAR(1₁) dengan menggunakan empat lokasi yang berbeda seperti persamaan berikut,

$$\mathbf{Z}(t) = \Phi_{10} \mathbf{Z}(t-1) + \Phi_{11} \mathbf{W}^{(1)} \mathbf{Z}(t-1) + \mathbf{e}(t) \quad (2.41)$$

dalam bentuk matriks, persamaan (2.41) dapat ditulis sebagai berikut

$$\begin{pmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \\ Z_4(t) \end{pmatrix} = \begin{pmatrix} \phi_{10} & 0 & 0 & 0 \\ 0 & \phi_{20} & 0 & 0 \\ 0 & 0 & \phi_{30} & 0 \\ 0 & 0 & 0 & \phi_{40} \end{pmatrix} + \begin{pmatrix} \phi_{11} & 0 & 0 & 0 \\ 0 & \phi_{21} & 0 & 0 \\ 0 & 0 & \phi_{31} & 0 \\ 0 & 0 & 0 & \phi_{41} \end{pmatrix} \begin{pmatrix} 0 & w_{12} & w_{13} & w_{14} \\ w_{21} & 0 & w_{23} & w_{24} \\ w_{31} & w_{32} & 0 & w_{34} \\ w_{41} & w_{42} & w_{43} & 0 \end{pmatrix} \begin{pmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \\ Z_4(t-1) \end{pmatrix} + \begin{pmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \end{pmatrix}.$$

Dalam mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde satu karena orde yang lebih tinggi akan sulit untuk diinterpretasikan (Wutsqa, Suhartono, dan Sutijo, 2010). Orde waktu (*autoregressive*) ditentukan dengan menggunakan *Akaike Information Criterion* (AIC) (Tsay, 2002). Akan tetapi penentuan orde model berdasarkan nilai AIC tidak dapat menangkap pola-pola *seasonal*, maka dari itu penentuan orde model juga dapat dilakukan berdasarkan plot MCCF dan MPCCF yang terbentuk.

Apabila data yang mengandung pola musiman, maka model GSTAR yang digunakan adalah model GSTAR musiman. Model umum GSTAR $(p, \lambda_1, \lambda_2, \dots, \lambda_p)^s$ untuk pola data musiman adalah sebagai berikut

$$\mathbf{Z}(t) = \sum_{k=1}^p \left[\Phi_{k0}^s \mathbf{Z}(t-s) + \sum_{l=1}^{\lambda_k} \Phi_{kl}^s \mathbf{W}^{(l)} \mathbf{Z}(t-s) \right] + \mathbf{e}(t), \quad (2.42)$$

dengan,

Φ_{k0}^s : $diag(\phi_{k0}^{(1)}, \dots, \phi_{k0}^{(N)})$ merupakan matriks parameter waktu musiman s ,
 Φ_{kl}^s : $diag(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$ merupakan matriks parameter spasial musiman s ,
 $\mathbf{e}(t)$: vektor *noise* berukuran $(N \times 1)$ yang independen, identik, berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarian $\sigma^2 \mathbf{I}_N$.

Nilai pembobot dipilih sedemikian hingga, sampai memenuhi syarat $w_{ii}^{(l)} = 0$ dan $\sum_{j \neq i} w_{ij}^{(l)} = 1$. Misal, pada model GSTAR musiman dengan orde musiman 1 dan periode musiman 12 ($s=12$) dan orde spasial 1 adalah sebagai berikut

$$\mathbf{Z}(t) = [\Phi_{10}^{12} \mathbf{Z}(t-12) + \Phi_{11}^1 \mathbf{W}^1 \mathbf{Z}(t-12)] + \mathbf{e}(t). \quad (2.43)$$

a. Penentuan Bobot Lokasi pada Model GSTAR

Terdapat beberapa cara dalam menentukan bobot lokasi pada model GSTAR, diantaranya bobot seragam, bobot biner, bobot *invers* jarak, bobot normalisasi korelasi silang, dan bobot normalisasi inferensi parsial korelasi silang (Borovkova, Lopuhaa, dan Ruchjana, 2002; Ruchjana, 2002; Suhartono dan Atok, 2006; Suhartono dan Subanar, 2006). Sebagai ilustrasi, berikut ini disajikan peta

empat lokasi Kantor Perwakilan Bank Indonesia di Wilayah Jawa Timur, yaitu Kota Surabaya, Kota Malang, Kota Kediri, dan Kabupaten Jember.



Gambar 2.3 Peta Lokasi dan Wilayah Kerja KPw BI Wilayah Jawa Timur

i. Bobot Seragam (Uniform)

Bobot lokasi seragam memberikan nilai bobot yang sama untuk setiap lokasi (mengasumsikan bahwa lokasi-lokasi yang digunakan dalam penelitian bersifat homogen). Penentuan nilai bobot dalam bobot lokasi seragam adalah sebagai berikut

$$w_{ij} = \frac{1}{s_i}, \quad (2.44)$$

dengan s_i adalah banyaknya lokasi yang berdekatan dengan lokasi ke- i . Sehingga untuk ilustrasi lokasi pada Gambar 2.3, matriks pembobotnya adalah

$$w_{ij} = \begin{bmatrix} 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & 0 & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & 0 & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} & 0 \end{bmatrix}.$$

ii. Bobot Biner

Metode dengan pembobot biner hanya bergantung pada keadaan yang terbatas. Pembobotan dengan metode biner memiliki pembobot dengan $w_{ij} = 0$

atau 1. Missal, ilustrasi lokasi pada Gambar 2.3, matriks pembobotnya adalah sebagai berikut

$$w_{ij} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}.$$

iii. Bobot Invers Jarak

Pembobotan dengan metode *invers* jarak dilakukan berdasarkan jarak sebenarnya antar lokasi di lapangan. Perhitungan bobot dengan metode *invers* jarak diperoleh dari normalisasi hasil *invers* jarak sebenarnya. Pada ilustrasi Gambar 2.3, perhitungan bobot jarak dari KPw Bank Indonesia Wilayah Jawa Timur adalah sebagai berikut

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^s \frac{1}{d_{ij}}}, \quad j \neq i. \quad (2.45)$$

Berikut ini adalah jarak lokasi masing-masing KPw Bank Indonesia Wilayah Jawa Timur (km).

Tabel 2.3 Jarak antar KPw Bank Indonesia Wilayah Jawa Timur (km)

KPw BI	Lokasi			
	Surabaya	Kediri	Malang	Jember
Surabaya	0	$d_{SK} = 133$	$d_{SM} = 99$	$d_{SJ} = 200$
Kediri	$d_{SK} = 133$	0	$d_{KM} = 100$	$d_{KJ} = 265$
Malang	$d_{SM} = 99$	$d_{KM} = 100$	0	$d_{MJ} = 183$
Jember	$d_{SJ} = 200$	$d_{KJ} = 265$	$d_{MJ} = 183$	0

Indeks pada Tabel 2.3 merupakan huruf pertama lokasi KPw BI. Didapatkan bobot antar lokasi KPw Bank Indonesia wilayah Jawa Timur, sebagai berikut

$$w_{SK} = \frac{\frac{1}{d_{SK}}}{\frac{1}{d_{SK}} + \frac{1}{d_{SM}} + \frac{1}{d_{SJ}}} = \frac{\frac{1}{133}}{\frac{1}{133} + \frac{1}{99} + \frac{1}{200}} = 0,33$$

$$w_{SM} = \frac{\frac{1}{d_{SM}}}{\frac{1}{d_{SK}} + \frac{1}{d_{SM}} + \frac{1}{d_{SJ}}} = \frac{\frac{1}{99}}{\frac{1}{133} + \frac{1}{99} + \frac{1}{200}} = 0,45$$

$$w_{SM} = \frac{\frac{1}{d_{SJ}}}{\frac{1}{d_{SK}} + \frac{1}{d_{SM}} + \frac{1}{d_{SJ}}} = \frac{\frac{1}{200}}{\frac{1}{133} + \frac{1}{99} + \frac{1}{200}} = 0,22 ; \text{ dst.}$$

Sehingga matriks pembobot yang diperoleh dengan metode *invers jarak* adalah

$$w_{ij} = \begin{bmatrix} 0 & 0,33 & 0,45 & 0,22 \\ 0,35 & 0 & 0,47 & 0,18 \\ 0,40 & 0,39 & 0 & 0,21 \\ 0,35 & 0,27 & 0,38 & 0 \end{bmatrix}.$$

iv. **Bobot Normalisasi Korelasi Silang**

Pembobotan dengan metode normalisasi korelasi silang adalah menggunakan hasil normalisasi korelasi silang antar lokasi pada *lag* yang bersesuaian yang pertama kali diperkenalkan oleh Suhartono dan Atok (2006). Secara umum korelasi silang antara lokasi ke-*i* dan ke-*j* pada *lag* waktu ke-*k*, $\text{corr}[Z_i(t), Z_j(t-k)]$, didefinisikan sebagai berikut

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k = 0, \pm 1, \pm 2, \dots \quad (2.46)$$

dengan $\gamma_{ij}(k)$ merupakan kovarians silang antara kejadian di lokasi ke-*i* dan ke-*j*, pada lag waktu ke-*k*, σ_i dan σ_j adalah standar deviasi dari kejadian di lokasi ke-*i* dan ke-*j*. Taksiran dari korelasi silang ini pada data sampel dapat dihitung dengan persamaan berikut,

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{\sqrt{\left(\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i]^2 \right) \left(\sum_{t=k+1}^n [Z_j(t) - \bar{Z}_j]^2 \right)}}. \quad (2.47)$$

Penentuan bobot lokasi dapat dilakukan melalui normalisasi dari hasil besaran-besaran korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR (1₁) seperti pada persamaan berikut,

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{k \neq i} |r_{ij}(1)|}, \quad (2.48)$$

dengan $i \neq j$ dan $\sum_{j \neq i} |w_{ij}| = 1$.

v. Bobot Normalisasi Inferensi Korelasi Silang Parsial

Pembobotan normalisasi inferensi korelasi silang parsial tidak jauh berbeda dengan pembobotan normalisasi. Secara umum korelasi silang antara lokasi ke- i dan ke- j pada lag waktu ke- k , $\text{corr}[Z_i(t), Z_j(t-k)]$, didefinisikan seperti pada persamaan (2.46). Taksiran dari persamaan korelasi silang data sampel dapat dilihat pada persamaan (2.47). Bartlett (1955) dalam Wei (2006) telah menurunkan varians dan kovarians dari korelasi silang yang diestimasi berdasarkan data sampel. Berdasarkan hipotesis, dua data *time series*, Z_i dan Z_j tidak berkorelasi yang ditunjukkan oleh persamaan,

$$\text{Var}[r_{ij}(k)] \cong \frac{1}{n-k} \left[1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s) \right]. \quad (2.49)$$

Ketika Z_i dan Z_j adalah merupakan deret yang *white noise* maka diperoleh,

$$\text{Var}[r_{ij}(k)] \cong \frac{1}{n-k}, \quad (2.50)$$

untuk ukuran sampel besar, $(n-k)$ pada persamaan (2.50) bisa diganti dengan n . Di bawah asumsi distribusi normal, maka nilai-nilai korelasi silang pada sampel ini dapat diuji apakah sama atau berbeda dengan nol. Proses inferensi statistik dilakukan dengan taksiran interval seperti pada persamaan berikut

$$r_{ij}(k) \pm \left[t_{\alpha/2; df=n-k-2} \frac{1}{\sqrt{n}} \right]. \quad (2.51)$$

Penentuan bobot lokasi dapat dilakukan melalui normalisasi dari hasil besaran-besaran korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR (1_1) seperti pada persamaan (2.48). Bobot-bobot lokasi dengan menggunakan normalisasi dari hasil inferensi statistik terhadap korelasi silang antar lokasi pada lag waktu yang bersesuaian ini memungkinkan semua bentuk kemungkinan hubungan antar lokasi. Dengan demikian, tidak ada lagi batasan yang kaku tentang besarnya bobot, terutama yang bergantung dari jarak antar lokasi. Bobot ini juga memberikan fleksibilitas pada besar dan tanda hubungan antar lokasi yang bisa berlainan (positif dan negatif) (Suhartono dan Atok, 2006).

b. Penaksiran Parameter Model GSTAR

Metode OLS merupakan metode estimasi dengan meminimumkan jumlah kuadrat simpangannya (Borovkova, Lopuhaa, dan Ruchjana, 2008). Informasi adanya residual yang berkorelasi antar persamaan menyebabkan penggunaan metode OLS tidak tepat. Sehingga diperlukan perbaikan penduga parameter model dengan menggunakan *Generalized Least Square* (GLS). GLS adalah penduga parameter regresi yang memperhatikan adanya korelasi dari residual antar persamaan, dengan nilai residual diperoleh dari penaksiran OLS.

i. Estimasi *Ordinary Least Square* (OLS)

Jika diketahui parameter regresi waktu Φ_{10} dan spasial Φ_{11} seperti pada persamaan (2.41), dengan $\mathbf{W}^{(1)}$ menyatakan bobot lokasi, maka model GSTAR (1_1) dapat dinyatakan dalam matriks sebagai berikut,

$$\mathbf{Z}(t) = \mathbf{A}\mathbf{Z}(t-1) + \mathbf{e}(t), \quad (2.52)$$

dengan $\mathbf{A} = \Phi_0 + \Phi_1\mathbf{W}$, Φ_0 dan Φ_1 merupakan matriks diagonal parameter autoregresi untuk waktu dan lokasi, dan \mathbf{W} merupakan matriks pembobot. Metode OLS sering digunakan dalam melakukan penaksiran parameter terhadap suatu model linier. Metode ini juga diterapkan pada model GSTAR(1_1) yang dapat ditulis dalam bentuk linier sebagai berikut,

$$\begin{pmatrix} Z_1(1) \\ Z_1(2) \\ \vdots \\ Z_1(T) \\ \vdots \\ Z_N(1) \\ Z_N(2) \\ \vdots \\ Z_N(T) \end{pmatrix} = \begin{pmatrix} Z_1(0) & V_1(0) & \cdots & 0 & 0 \\ Z_1(1) & V_1(1) & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ Z_1(T-1) & V_1(T-1) & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & Z_N(0) & V_N(0) \\ 0 & 0 & \cdots & Z_N(1) & V_N(1) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & Z_N(T-1) & V_N(T-1) \end{pmatrix} \begin{pmatrix} \phi_{01} \\ \phi_{11} \\ \vdots \\ \phi_{0N} \\ \phi_{1N} \end{pmatrix} + \begin{pmatrix} e_1(1) \\ e_1(2) \\ \vdots \\ e_1(T) \\ \vdots \\ e_N(1) \\ e_N(2) \\ \vdots \\ e_N(T) \end{pmatrix} \quad (2.53)$$

dengan $V_i(t) = \sum_{j \neq i} w_{ij} Z_j(t)$. Secara umum dapat ditulis sebagai $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$,

dengan

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_N \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} \mathbf{X}_1 & 0 & \cdots & 0 \\ 0 & \mathbf{X}_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{X}_N \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_N \end{pmatrix}, \quad \mathbf{e} = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{pmatrix},$$

dengan $i = 1, 2, \dots, N$, sehingga struktur model linier dari GSTAR (p_1) adalah

$$\mathbf{Y}_i = \begin{pmatrix} Z_i(p) \\ Z_i(p+1) \\ \vdots \\ Z_i(T) \end{pmatrix}, \quad \mathbf{X}_i = \begin{pmatrix} Z_i(p) & \cdots & Z_i(1) & V_i(p) & \cdots & V_i(1) \\ Z_i(p+1) & \cdots & Z_i(2) & V_i(p+1) & \cdots & V_i(2) \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ Z_i(T-1) & \cdots & Z_i(T-p) & V_i(T-1) & \cdots & V_i(T-p) \end{pmatrix},$$

$$\boldsymbol{\beta}_i = \begin{pmatrix} \phi_{10}^{(i)} \\ \vdots \\ \phi_{p0}^{(i)} \\ \phi_{11}^{(i)} \\ \vdots \\ \phi_{p1}^{(i)} \end{pmatrix}.$$

hal ini berarti estimator *least square* untuk $\boldsymbol{\beta}_i$ dapat dihitung secara terpisah pada masing-masing lokasi namun tetap bergantung pada nilai $\mathbf{Z}(t)$ di lokasi yang lain dan untuk struktur model linier dari GSTAR (1_1) menjadi $\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta}_i + \mathbf{e}_i$,

$$\mathbf{Y}_i = \begin{pmatrix} Z_i(1) \\ Z_i(2) \\ \vdots \\ Z_i(T) \end{pmatrix}, \mathbf{X}_i = \begin{pmatrix} Z_i(0) & V_i(0) \\ Z_i(1) & V_i(1) \\ \vdots & \vdots \\ Z_i(T-1) & V_i(T-1) \end{pmatrix}, \boldsymbol{\beta}_i = \begin{pmatrix} \phi_{i0} \\ \phi_{i1} \end{pmatrix}, \text{ dan } \mathbf{e}_i = \begin{pmatrix} e_i(1) \\ e_i(2) \\ \vdots \\ e_i(T) \end{pmatrix},$$

dengan $\mathbf{V}_i(t) = \sum_{j \neq i} w_{ij} Z_j(t)$.

Berdasarkan matrik di atas, nilai taksiran untuk $\boldsymbol{\beta} = (\phi_{10}, \phi_{11}, \phi_{20}, \phi_{21}, \dots, \phi_{N0}, \phi_{N1})'$ dengan $T \rightarrow \infty$, dapat dihitung menggunakan estimator *least square* menjadi $\hat{\boldsymbol{\beta}}_T = (\hat{\phi}_{10}, \hat{\phi}_{11}, \hat{\phi}_{20}, \hat{\phi}_{21}, \dots, \hat{\phi}_{N0}, \hat{\phi}_{N1})'$ sehingga,

$$\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}_T = \mathbf{X}'\mathbf{Y} = \mathbf{X}'(\mathbf{X}\boldsymbol{\beta} + \mathbf{e}) = \mathbf{X}'\mathbf{X}\boldsymbol{\beta} + \mathbf{X}'\mathbf{e} \quad (2.54)$$

secara tidak langsung menyatakan $\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}}_T - \boldsymbol{\beta}) = \mathbf{X}'\mathbf{e}$. Elemen-elemen dari matriks $\mathbf{X}'\mathbf{X}$ adalah

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} \mathbf{X}'_1\mathbf{X}_1 & 0 & \dots & 0 \\ 0 & \mathbf{X}'_2\mathbf{X}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}'_N\mathbf{X}_N \end{pmatrix}, \text{ dengan}$$

$$\mathbf{X}'_i\mathbf{X}_i = \begin{pmatrix} \sum_{t=0}^{T-1} Z_i(t)^2 & \sum_{t=0}^{T-1} Z_i(t)V_i(t) \\ \sum_{t=0}^{T-1} Z_i(t)V_i(t) & \sum_{t=0}^{T-1} V_i(t)^2 \end{pmatrix} \text{ dan } \mathbf{V}_i(t) = \sum_{j \neq i} w_{ij} Z_j(t).$$

Metode *least square* pada estimasi parameter model dapat dilakukan dengan meminimumkan fungsi

$$\mathbf{e} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}), \quad (2.55)$$

dengan demikian hasil estimator $\boldsymbol{\beta}$ didapat sebagai berikut

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}, \quad (2.56)$$

untuk vektor parameter ϕ_{i0} dan ϕ_{i1} , $i = 1, 2, \dots, N$ adalah

$$\hat{\phi}_i = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}_i. \quad (2.57)$$

ii. Estimasi *Generalized Least Square* (GLS)

Generalized Least Square (GLS) sering digunakan di dalam model *Seemingly Unrelated Regression* (SUR). Model SUR merupakan sistem persamaan regresi linear yang dapat mengatasi masalah korelasi residual antar persamaan untuk menghasilkan estimator model regresi. Model SUR merupakan suatu metode estimasi model yang terdiri dari beberapa persamaan dan variabel-variabelnya tidak bersifat dua arah, akan tetapi antara persamaan-persamaan tersebut terjadi kaitan satu sama lainnya sehingga terjadi korelasi antara kesalahan-kesalahan persamaan tersebut (Zellner, 1962). Wahyuningrum (2014) yang membandingkan metode estimasi menggunakan SUR dan OLS dari data simulasi antar lokasi saling berkorelasi atau tidak semua saling berkorelasi, menyimpulkan bahwa nilai *standart error* untuk model GSTAR-SUR dan GSTARX-SUR, lebih kecil dibandingkan model GSTAR-OLS dan GSTARX-OLS. Hal ini berarti estimasi parameter dengan model GSTARX-SUR lebih efisien dibandingkan dengan model GSTARX-OLS. Secara umum model SUR ditulis sebagai berikut,

$$\begin{aligned} Z_{1t} &= \beta_{10} + \beta_{11}X_{1t,1} + \beta_{12}X_{1t,2} + \cdots + \beta_{1K_1}X_{1t,K_1} + e_{1t} \\ Z_{2t} &= \beta_{20} + \beta_{21}X_{2t,1} + \beta_{22}X_{2t,2} + \cdots + \beta_{2K_2}X_{2t,K_2} + e_{2t} \\ &\vdots \\ Z_{Nt} &= \beta_{N0} + \beta_{N1}X_{Nt,1} + \beta_{N2}X_{Nt,2} + \cdots + \beta_{NK_N}X_{Nt,K_N} + e_{Nt} \end{aligned} \quad (2.58)$$

dengan $t = 1, 2, \dots, T$, dimana T merupakan banyak pengamatan, K banyak variabel bebas, N menyatakan banyak persamaan dalam sistem, dan $e_{1t}, e_{2t}, \dots, e_{Nt}$ berkorelasi. Model SUR dengan N variabel dependen dinyatakan dengan persamaan sebagai berikut

$$\mathbf{Z}_i = \mathbf{X}_i\boldsymbol{\beta}_i + \mathbf{e}_i \quad (2.59)$$

dengan $i = 1, 2, \dots, N$. \mathbf{Z}_i adalah vektor pengamatan terurut berukuran $T \times 1$ pada variabel dependen, \mathbf{X}_i merupakan matriks pengamatan berukuran $T \times k$ pada variabel independen, $\boldsymbol{\beta}_i$ adalah vektor parameter berukuran $k \times 1$, dan \mathbf{e}_i

merupakan vektor residual berukuran $T \times 1$. Persamaan (2.59) dapat ditulis dalam bentuk matriks sebagai berikut,

$$\begin{pmatrix} \mathbf{Z}_1 \\ \mathbf{Z}_2 \\ \vdots \\ \mathbf{Z}_N \end{pmatrix}_{(T \times 1)} = \begin{pmatrix} \mathbf{X}_1 & 0 & \cdots & 0 \\ 0 & \mathbf{X}_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mathbf{X}_N \end{pmatrix}_{(T \times k)} \begin{pmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \\ \vdots \\ \boldsymbol{\beta}_N \end{pmatrix}_{(k \times 1)} + \begin{pmatrix} \mathbf{e}_1 \\ \mathbf{e}_2 \\ \vdots \\ \mathbf{e}_N \end{pmatrix}_{(T \times 1)} \quad (2.60)$$

atau $\mathbf{Z} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$. Asumsi yang harus dipenuhi dalam persamaan model SUR adalah $E(\mathbf{e}) = 0$ dan $E(\mathbf{e}_i \mathbf{e}_j') = \boldsymbol{\sigma}_{ij} \mathbf{I}$. Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR diberikan dengan

$$E[\mathbf{e}_i \mathbf{e}_j'] = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix} \begin{bmatrix} e_1 & e_2 & \cdots & e_N \end{bmatrix}, \quad (2.61)$$

persamaan (2.61) apabila diuraikan menjadi

$$E[\mathbf{e}_i \mathbf{e}_j'] = \begin{bmatrix} E(e_1 e_1) & E(e_1 e_2) & \cdots & E(e_1 e_N) \\ E(e_2 e_1) & E(e_2 e_2) & \cdots & E(e_2 e_N) \\ \vdots & \vdots & \ddots & \vdots \\ E(e_N e_1) & E(e_N e_2) & \cdots & E(e_N e_N) \end{bmatrix}. \quad (2.62)$$

Karena $E(\mathbf{e}_i \mathbf{e}_j') = \boldsymbol{\sigma}_{ij} \mathbf{I}$ sehingga dapat dituliskan

$$E[\mathbf{e}_i \mathbf{e}_j'] = \begin{pmatrix} \sigma_{11} \mathbf{I} & \sigma_{12} \mathbf{I} & \cdots & \sigma_{1N} \mathbf{I} \\ \sigma_{21} \mathbf{I} & \sigma_{22} \mathbf{I} & \cdots & \sigma_{2N} \mathbf{I} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} \mathbf{I} & \sigma_{N1} \mathbf{I} & \cdots & \sigma_{NN} \mathbf{I} \end{pmatrix}. \quad (2.63)$$

Persamaan (2.63) apabila diuraikan dengan perkalian Kronecker (\otimes) menjadi

$$\begin{aligned}
E[\mathbf{e}_i \mathbf{e}_j'] &= \begin{pmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N1} & \cdots & \sigma_{NN} \end{pmatrix} \otimes \mathbf{I} \\
&= \mathbf{\Sigma} \otimes \mathbf{I} \\
&= \mathbf{\Omega},
\end{aligned} \tag{2.64}$$

$$\text{dengan } \mathbf{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N1} & \cdots & \sigma_{NN} \end{bmatrix} \text{ dan } \mathbf{I} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}.$$

$\mathbf{\Sigma}$ merupakan matriks varians-kovarians *error* berukuran $(N \times N)$ dan \mathbf{I} merupakan matriks identitas berukuran $(T \times T)$.

Salah satu pendekatan yang dapat digunakan dalam mengestimasi parameter model SUR adalah metode GLS (Baltagi, 1980) yang merupakan pengembangan dari OLS. Jika proses estimasi parameter pada OLS dilakukan dengan cara meminimumkan fungsi persamaan (2.55), maka untuk GLS dapat dikembangkan dengan cara meminimumkan fungsi $\mathbf{e}'\mathbf{e} = (\mathbf{Z} - \mathbf{X}\boldsymbol{\beta})'\mathbf{\Omega}^{-1}(\mathbf{Z} - \mathbf{X}\boldsymbol{\beta})$. Sehingga estimator untuk $\boldsymbol{\beta}$ diperoleh dengan rumus sebagai berikut

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{Z}. \tag{2.65}$$

c. Kondisi Stasioner Parameter Model GSTAR

Ruchjana (2002) menyatakan bahwa model GSTAR khususnya GSTAR(1₁) merupakan versi yang terbatas dari model VAR. Oleh karena itu, kondisi stasioner model GSTAR dapat diperoleh dari kondisi stasioner model VAR. Model GSTAR(1₁), $\mathbf{Z}(t) = [\boldsymbol{\Phi}_{10} + \boldsymbol{\Phi}_{11}\mathbf{W}^{(1)}]\mathbf{Z}(t-1) + \mathbf{e}(t)$ dapat diwakili dengan model VAR(1), $\mathbf{Z}(t) = \boldsymbol{\Phi}_1\mathbf{Z}(t-1) + \mathbf{e}(t)$, dengan

$$\boldsymbol{\Phi}_1 = [\boldsymbol{\Phi}_{10} + \boldsymbol{\Phi}_{11}\mathbf{W}^{(1)}] \tag{2.66}$$

secara umum model GSTAR yang merupakan proses stasioner adalah jika semua *eigenvalue* dari matriks $[\boldsymbol{\Phi}_{10} + \boldsymbol{\Phi}_{11}\mathbf{W}^{(1)}]$ memenuhi syarat $|\lambda| < 1$.

Suhartono dan Subanar (2007) menyatakan bahwa kondisi stasioner pada model GSTAR, khususnya untuk parameter pada model GSTAR(1₁) dapat menggunakan syarat $|\lambda| < 1$ yang disajikan dalam model VAR(1). Oleh karena itu, untuk mengecek kondisi stasioner parameter model GSTAR(1₁) harus disajikan dalam bentuk VAR(1) terlebih dahulu.

d. Peramalan Metode GSTAR

Bentuk umum peramalan model GSTAR dapat ditulis seperti persamaan berikut,

$$\hat{Z}(t) = \sum_{k=1}^p \left[\Phi_{k0} Z(t-s) + \sum_{l=1}^{\lambda_k} \Phi_{kl} W^{(l)} Z(t-s) \right]. \quad (2.67)$$

2.3 Uji Terasvirta

Tahap pertama sebelum melakukan pemodelan *time series* nonlinier adalah melakukan uji linieritas pada data *time series*. Ada beberapa uji nonlinieritas, salah satunya adalah uji Terasvirta, yang dikembangkan oleh Terasvirta, dkk (1993). Uji Terasvirta merupakan uji yang dikembangkan dari model *neural networks* dan termasuk dalam kelompok uji tipe Lagrange Multiplier (LM) yang dikembangkan dengan ekspansi Taylor. Implementasi praktis uji Terasvirta dapat dilakukan melalui dua statistik uji, yaitu uji χ^2 atau uji F . Prosedur untuk mendapatkan uji F adalah sebagai berikut,

1. Meregresikan Z_t pada $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ kemudian hitung nilai residual

$$\hat{u}_t = Z_t - \hat{Z}_t \text{ serta jumlah kuadrat residual } SSE_0 = \sum \hat{u}_t^2.$$

2. Meregresikan \hat{u}_t pada $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ dan m prediktor tambahan, kemudian

$$\text{hitung nilai residual } \hat{v}_t = \hat{u}_t - \hat{\hat{u}}_t \text{ serta jumlah kuadrat residual } SSE_1 = \sum \hat{v}_t^2.$$

3. Hitung statistik $F = \frac{(SSR_0 - SSR_1) / m}{SSR_1 / (n - p - 1 - m)}$, dengan n adalah banyaknya pengamatan yang digunakan.

Tolak H_0 apabila $F_{hitung} > F_{(\alpha; m, (n-p-1-m))}$ atau P-value kurang dari α , ini berarti suatu model linier dikatakan sebagai *neglected nonlinearity*. Pada kondisi ini perlu dibangun model nonlinier untuk estimasi model yang lebih sesuai.

2.4 Artificial Neural Network (ANN)


Artificial Neural Network (ANN) atau jaringan saraf tiruan merupakan suatu sistem pemrosesan informasi yang memiliki karakteristik performa tertentu dalam jaringan saraf biologis, dalam penelitian ini ANN dipandang sebagai suatu obyek matematika atau secara khusus sebagai suatu model *time series*, dengan asumsi sebagai berikut

- i. Pemrosesan informasi terjadi pada *simple element* yang disebut *neuron*.
- ii. Sinyal dilewatkan di antara neuron di atas *connection links*.
- iii. Masing-masing *connection link* memiliki bobot yang dikalikan dengan sinyal yang ditransmisi.
- iv. Masing-masing *neuron* menggunakan fungsi aktivasi pada *net input* (jumlahan sinyal input terboboti) untuk menentukan sinyal *output*.

Sebuah neural network digolongkan berdasarkan pola *connection* di antara neuron (disebut juga arsitektur), metode dalam menentukan bobot dari *connection* (disebut *training*, *learning*, atau *algoritma*), dan fungsi aktivasi (Fausett, 1994). Sebelum melakukan pemodelan menggunakan ANN, dilakukan pengujian linieritas terlebih dahulu pada data yang akan dianalisis. Pengujian linieritas dapat dilakukan menggunakan uji Terasvirta, uji RESET, uji Keenan, dan uji Tsay. Pada penelitian ini, pengujian linieritas akan dilakukan menggunakan uji Terasvirta.

Apabila terdapat pola nonlinieritas pada data, maka model ANN dapat digunakan. Ada banyak jenis desain ANN, diantaranya *back-propagation (feed forward)*, *recurrent network*, *self-organizing map*, *radial basis function network*, dan sebagainya. Metode ANN yang banyak digunakan dalam peramalan adalah *feedforward neural network* (FFNN). Pada FFNN, proses dimulai dari *input* yang diterima oleh *neuron*, dimana *neuron-neuron* ini dikelompokkan dalam *layer*. Informasi yang diterima dari *layer input* dilanjutkan ke *layer* dalam FFNN secara

berurutan hingga mencapai *layer output*. *Layer* yang berada diantara *input* dan *output* disebut *hidden layer*. Gambar 2.4 merupakan contoh arsitektur FFNN.



Gambar 2.4 Arsitektur FFNN


Berikut ini adalah persamaan dalam pencarian *output* dari arsitektur FFNN pada Gambar 2.4 (Taylor, 2000).

$$\hat{Y}_t = f^o \left\{ v_0 + \sum_{k=1}^K \left(v_k f^h \left(w_{0k} + \sum_{i=1}^I w_{ik} x_{i,t} \right) \right) \right\} \quad (2.68)$$

dengan v_k merupakan pembobot *neuron* ke- k pada *hidden layer*, w_{ik} adalah bobot dari *input* ke- i menuju *neuron* ke- k pada *hidden layer*, $f^h(\bullet)$ adalah fungsi aktivasi pada *hidden layer*, dan $f^o(\bullet)$ adalah fungsi aktivasi pada *output layer*. Fungsi aktivasi pada *output layer* dapat berupa fungsi linier, sedangkan pada *hidden layer* dapat menggunakan fungsi *hyperbolic tangent* (\tanh), yaitu:

$$f^h(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} = \frac{1 + e^{-2x}}{1 - e^{-2x}}. \quad (2.69)$$

Fungsi ini menghasilkan nilai berkisar antara -1 sampai 1 seperti Gambar 2.5.



Gambar 2.5 Fungsi *Hyperbolic Tangent*

Parameter ANN disebut bobot, yang biasanya diestimasi dengan algoritma pembelajaran yang diawasi (*supervised learning algorithm*). Terdapat beberapa macam algoritma dalam ANN, salah satunya adalah algoritma *backpropagation*. Berikut ini merupakan urutan langkah-langkah dalam algoritma *backpropagation* secara detail (Fausett, 1994).

Langkah 1: Inisiasi bobot.

Langkah 2: Selama kondisi berhenti salah, kerjakan langkah 3 sampai dengan 8.

Langkah 3: Tiap unit *input* ($x_i, i=1, \dots, I$) menerima isyarat masukan x_i dan diteruskan ke unit-unit *hidden layer*.

Langkah 4: Tiap *hidden layer* ($z_k, k=1, \dots, K$) menjumlahkan bobot sinyal *input*.

$$z_in_k = w_{0k} + \sum_{i=1}^I x_i w_{ik}. \quad (2.70)$$

Dengan menerapkan fungsi aktivasi hitung sebagai berikut

$$z_k = f(z_in_k). \quad (2.71)$$

Apabila fungsi aktivasi yang digunakan adalah *hyperbolic tangent*, maka hasil keluaran yang didapat pada *hidden layer* seperti persamaan berikut

$$z_k = \tanh(z_in_k). \quad (2.72)$$

Kemudian mengirimkan isyarat ini pada unit *output*.

Langkah 5: Unit *output* (y) menjumlahkan isyarat masukan berbobot.

$$y_in = v_0 + \sum_{k=1}^K z_k v_k. \quad (2.73)$$

Dengan menerapkan fungsi aktivasi hitung sebagai berikut

$$y = f(y_in). \quad (2.74)$$

Langkah 6: Unit *output* (y) menerima pola pelatihan masukannya dan menghitung *error* informasinya, dengan t merupakan *output* target

$$\delta = (t - y) f'(y_in). \quad (2.75)$$

Hitung koreksi bobot dan biasnya.

$$\Delta v_k = \alpha \delta z_k. \quad (2.76)$$

$$\Delta v_0 = \alpha \delta. \quad (2.77)$$

Langkah 7: Tiap *hidden layer* ($z_k, k=1, \dots, K$) menghitung delta masukannya (dari unit-unit yang berada pada lapisan atasnya).

$$\delta_{in_k} = \delta v_k. \quad (2.78)$$

Hitung *error* informasinya.

$$\delta_k = \delta_{in_k} f'(z_{in_k}). \quad (2.79)$$

Hitung koreksi bobot dan biasnya.

$$\Delta w_{ik} = \alpha \delta_k x_i. \quad (2.80)$$

Langkah 8: Unit keluaran (y) memperbarui bobot dan bias.

$$v_0(\text{baru}) = v_0(\text{lama}) + \Delta v_0. \quad (2.81)$$

$$v_k(\text{baru}) = v_k(\text{lama}) + \Delta v_k. \quad (2.82)$$

Tiap *hidden layer* ($z_k, k=1, \dots, K$) memperbarui bobot dan biasnya.

$$w_{ik}(\text{baru}) = w_{ik}(\text{lama}) + \Delta w_{ik}. \quad (2.83)$$

Langkah 9: Uji syarat berhenti.

Langkah 3, 4, dan 5 merupakan langkah *feedforward*, langkah 6 dan 7 termasuk *backpropagation*, sedangkan langkah 8 dan 9 adalah untuk memperbaiki bobot dan bias. Algoritma *backpropagation* dapat melakukan pelatihan hingga didapatkan hasil yang paling optimum. Cara algoritma *backpropagation* memaksimalkan hasil pelatihan adalah dengan meminimalkan besar *error* yang terjadi. Pada algoritma ini, *error* diminimalisir dengan cara memodifikasi pembobot yang digunakan dalam perhitungan. Ketika ditemukan bobot baru, proses pelatihan akan dilakukan kembali. Proses ini akan dilakukan secara berulang-ulang dan akan berhenti pada saat didapatkan eror yang telah memenuhi uji syarat berhenti.

2.5 Model Variasi Kalender

Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Di sebagian besar negara Islam, data series ekonomi atau bisnis dapat didekati dengan dua jenis efek kalender, yaitu hari kerja dan efek liburan. Secara umum, tingkat ekonomi atau aktivitas bisnis bisa berubah tergantung pada hari kerja

dalam seminggu. Karena komposisi hari dalam seminggu bervariasi dari bulan ke bulan dan dari tahun ke tahun, rangkaian yang diamati dapat dipengaruhi oleh variasi tersebut. Hal ini yang mendasari terjadinya efek variasi kalender pada data *time series* (Lee, Suhartono, dan Hamzah, 2010).

Model variasi kalender dapat dimodelkan dengan menggunakan regresi. Model regresi linier untuk data yang menggunakan variasi kalender dapat ditulis sebagai berikut

$$Y_t = \beta_0 + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_p V_{p,t} + e_t, \quad (2.84)$$

dengan $V_{p,t}$ merupakan variabel *dummy* untuk efek variasi kalender ke- p dan e_t merupakan komponen *error* yang memenuhi asumsi identik, independen, dan berdistribusi normal dengan rata-rata nol dan varians σ^2 . Penentuan banyaknya efek variasi kalender dapat diidentifikasi berdasarkan plot deret waktu dari data atau statistika deskriptif (Lee, Suhartono, dan Hamzah, 2010).

Secara umum, model variasi kalender berdasarkan metode regresi jika terdapat tren, *seasonal*, dan *dummy* efek variasi kalender (misal, lebaran Idul Fitri) pada data, maka model *inflow* dapat dituliskan

$$Y_{i,t} = \delta_1 t + \delta_2 D_{2,t} + \delta_3 D_{3,t} + \delta_4 tD_{2,t} + \delta_5 tD_{3,t} + \sum_{m=1}^{12} \beta_m S_{m,t} + \sum_g \alpha_g L_{g,t} + \sum_g \varphi_g L_{g,t+1} + e_{i,t}. \quad (2.85)$$

Sedangkan model *outflow* ditulis seperti persamaan berikut

$$Y_{i,t} = \delta_1 t + \delta_2 D_{2,t} + \delta_3 D_{3,t} + \delta_4 tD_{2,t} + \delta_5 tD_{3,t} + \sum_{m=1}^{12} \beta_m S_{m,t} + \sum_g \alpha_g L_{g,t} + \sum_g \gamma_g L_{g,t-1} + e_{i,t}, \quad (2.86)$$

dengan δ merupakan parameter tren linier, $S_{1,t}, S_{2,t}, \dots, S_{12,t}$ merupakan variabel *dummy* musiman, dalam penelitian ini adalah bulan. α , φ , dan γ merupakan parameter variasi kalender untuk efek lebaran terhadap kejadian bulan saat terjadinya lebaran Idul Fitri, satu bulan setelah dan satu bulan sebelum terjadinya lebaran Idul Fitri.

2.6 Model *Hybrid* GSTARX-ANN

Model *hybrid* pertama kali diperkenalkan oleh Zhang (2003) dengan tujuan untuk menambah keakuratan ramalan. Model *hybrid* mengombinasikan komponen linier dan komponen nonlinier yang secara matematis dapat ditulis seperti persamaan berikut

$$Y_t = L_t + N_t + e_t, \quad (2.87)$$

dengan, L_t merupakan komponen linier dan N_t merupakan komponen nonlinier. Dalam penelitian ini, pemodelan *hybrid* dilakukan secara dua tahap. Tahap pertama yaitu memodelkan pola tren, musiman, dan variasi kalender menggunakan TSR sebagai komponen linier. Tahap kedua yaitu memodelkan residual tahap pertama dengan GSTAR-ANN. Model GSTAR-ANN yang digunakan terdiri dari GSTAR-FFNN dengan satu *hidden layer* dan GSTAR-DLNN dengan dua *hidden layer*.

2.7 Evaluasi Model

Evaluasi model dilakukan untuk mengetahui seberapa baik model yang terbentuk berdasarkan residual yang dihasilkan. Kriteria pemilihan model terbaik yang digunakan adalah AIC untuk kriteria *in sample* dan RMSE untuk kriteria *out of sample*. Nilai AIC diperoleh seperti pada persamaan (2.30) dan nilai RMSE diperoleh dari persamaan (2.33). Selain itu, juga digunakan kriteria *Mean Absolute Percentage Error* (MAPE) untuk mengetahui persentase kesalahan ramalan. MAPE diperoleh dengan perhitungan sebagai berikut

$$MAPE = \frac{\sum_{l=1}^M \left| \frac{Z_{n+l} - \hat{Z}_n(l)}{Z_{n+l}} \right|}{M} \times 100. \quad (2.88)$$

dengan n merupakan banyaknya data *in sample*, M merupakan banyaknya data *out of sample*, Z_{n+l} merupakan data aktual ke- l dan $\hat{Z}_n(l)$ merupakan data ramalan l tahap kedepan.

2.8 Penyetoran dan Penarikan Uang Rupiah di Bank Indonesia

Transaksi penarikan uang rupiah (*outflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang keluar dari Bank Indonesia kepada perbankan dan masyarakat, terdiri dari penarikan bank umum, penarikan nonbank, kas keliling dalam rangka penukaran, penarikan dalam rangka kas titipan di bank umum, dan penarikan lainnya. Transaksi penyetoran uang rupiah (*inflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia, terdiri dari setoran bank umum, setoran nonbank, kas keliling dalam rangka hasil penukaran, penyetoran dalam rangka kas titipan di bank umum, dan penyetoran lainnya (Bank Indonesia, 2013c).

BAB 3

METODOLOGI PENELITIAN

Pada bab ini dibahas tahapan penelitian yang meliputi studi simulasi dan kajian terapan menggunakan metode GSTARX dan *hybrid* GSTARX-ANN. Data simulasi mengandung komponen tren, musiman, variasi kalender, dan deret *noise* yang linier maupun nonlinier. Sedangkan kajian terapan menggunakan data *inflow* dan *outflow* uang kartal di Kota Surabaya, Malang, Kediri dan Jember.

3.1 Studi Simulasi

Studi simulasi dilakukan untuk mengetahui kebaikan model *hybrid* GSTARX-ANN dalam memodelkan data *time series*, jika data mengandung komponen tren, musiman, variasi kalender, dan deret *noise* yang linier maupun nonlinier. Langkah analisis dalam melakukan kajian simulasi adalah sebagai berikut:

- a. Membangkitkan data yang mengandung komponen tren, musiman, dan variasi kalender (efek lebaran Idul Fitri) dengan persamaan sebagai berikut,

$$Z_t^{(i)} = T_t^{(i)} + S_t^{(i)} + V_t^{(i)} + N_t^{(i)} \quad (3.1)$$

$i = 1, 2, 3$ yang menyatakan lokasi dengan,

- i. Komponen tren yang digunakan merupakan komponen linier dengan persamaan sebagai berikut,

$$T_t^{(i)} = \delta^{(i)} t. \quad (3.2)$$

Koefisien untuk tren yang digunakan dalam seluruh skenario adalah sama, yakni $\delta^{(1)} = 0,21$; $\delta^{(2)} = 0,23$; $\delta^{(3)} = 0,24$.

- ii. Komponen musiman didapat dengan persamaan sebagai berikut,

$$S_t^{(i)} = \gamma_1^{(i)} S_{1,t} + \gamma_2^{(i)} S_{2,t} + \dots + \gamma_{12}^{(i)} S_{12,t}. \quad (3.3)$$

dengan,

$$S_t^{(1)} = 22S_{1,t} + 24S_{2,t} + 27S_{3,t} + 24S_{4,t} + 22S_{5,t} + 17S_{6,t} + 13S_{7,t} + 10S_{8,t} + 6S_{9,t} \\ + 10S_{10,t} + 13S_{11,t} + 17S_{12,t}.$$

$$S_t^{(2)} = 25S_{1,t} + 28S_{2,t} + 30S_{3,t} + 28S_{4,t} + 25S_{5,t} + 21S_{6,t} + 16S_{7,t} + 13S_{8,t} + 9S_{9,t} \\ + 13S_{10,t} + 16S_{11,t} + 21S_{12,t}.$$

$$S_t^{(3)} = 17S_{1,t} + 21S_{2,t} + 24S_{3,t} + 21S_{4,t} + 17S_{5,t} + 12S_{6,t} + 9S_{7,t} + 6S_{8,t} + 4S_{9,t} \\ + 6S_{10,t} + 9S_{11,t} + 12S_{12,t}.$$

- iii. Komponen untuk variasi kalender pada kajian simulasi ini hanya menggunakan model simulasi data *outflow*, sehingga efek variasi kalender yang digunakan adalah pada saat terjadinya Idul Fitri dan satu bulan sebelum terjadinya Idul Fitri, dengan persamaan sebagai berikut,

$$V_t^{(i)} = \nu_1^{(i)}V_{1,t} + \dots + \nu_4^{(i)}V_{4,t} + \nu_1^{(i)}V_{1,t-1} + \dots + \nu_4^{(i)}V_{4,t-1}. \quad (3.4)$$

dengan,

$$V_t^{(1)} = 32V_{1,t} + 43V_{2,t} + 47V_{3,t} + 49V_{4,t} + 50V_{1,t-1} + 46V_{2,t-1} + 39V_{3,t-1} + 34V_{4,t-1}.$$

$$V_t^{(2)} = 45V_{1,t} + 49V_{2,t} + 55V_{3,t} + 57V_{4,t} + 60V_{1,t-1} + 54V_{2,t-1} + 44V_{3,t-1} + 36V_{4,t-1}.$$

$$V_t^{(3)} = 37V_{1,t} + 40V_{2,t} + 47V_{3,t} + 51V_{4,t} + 49V_{1,t-1} + 47V_{2,t-1} + 41V_{3,t-1} + 37V_{4,t-1}.$$

- iv. Komponen untuk deret *noise* yang digunakan dalam kajian simulasi terdiri dari *noise* pola linier (3.5) dan nonlinier (3.6), sebagai berikut

$$N_t^{(i)} = \phi_1^{(i)}N_{1,t-1} + \phi_2^{(i)}N_{2,t-1} + \phi_3^{(i)}N_{3,t-1} + a_t^{(i)}, \quad (3.5)$$

dengan,

$$N_t^{(1)} = 0,45N_{t-1}^{(1)} + 0,25N_{t-1}^{(2)} + 0,25N_{t-1}^{(3)} + a_t^{(1)}.$$

$$N_t^{(2)} = 0,15N_{t-1}^{(1)} + 0,40N_{t-1}^{(2)} + 0,15N_{t-1}^{(3)} + a_t^{(2)}.$$

$$N_t^{(3)} = 0,20N_{t-1}^{(1)} + 0,20N_{t-1}^{(2)} + 0,35N_{t-1}^{(3)} + a_t^{(3)}.$$

$$N_{1,t} = 4N_{1,t-1} \times \exp(-0,25N_{1,t-1}^2) + 1,25N_{2,t-1} \times \exp(-0,25N_{2,t-1}^2) + \\ 1,5N_{3,t-1} \times \exp(-0,25N_{3,t-1}^2) + a_{1,t}, \\ N_{2,t} = 1,25N_{1,t-1} \times \exp(-0,25N_{1,t-1}^2) + 3,5N_{2,t-1} \times \exp(-0,25N_{2,t-1}^2) + \\ 1,6N_{3,t-1} \times \exp(-0,25N_{3,t-1}^2) + a_{2,t}, \\ N_{3,t} = 1,6N_{1,t-1} \times \exp(-0,25N_{1,t-1}^2) + 1,1N_{2,t-1} \times \exp(-0,25N_{2,t-1}^2) + \\ 3N_{3,t-1} \times \exp(-0,25N_{3,t-1}^2) + a_{3,t}. \quad (3.6)$$

dengan $\mathbf{a}_t \sim MN(\mathbf{0}, \Sigma)$ dan antar lokasi saling berkorelasi.

- b. Mendapatkan data deret waktu $Z_{i,t}$, dengan $i=1, 2, 3$ yang berarti ada 3 lokasi dan $t=1, 2, \dots, 192$, dengan skenario sebagai berikut,

- i. Skenario 1, *noise* merupakan deret yang belum *white noise* berpola linier.
- ii. Skenario 2, *noise* merupakan deret yang belum *white noise* dan berpola nonlinier.
- c. Melakukan pemodelan menggunakan metode GSTARX dan *hybrid* GSTARX-ANN pada data $Z_{i,t}$ dengan menggunakan bobot seragam sesuai dengan skenario pada tahap (b) dengan replikasi sebanyak 10 kali.
- d. Melakukan perbandingan menggunakan metode GSTARX dan *hybrid* GSTARX-ANN dan menentukan metode terbaik dalam meramalkan data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* yang linier maupun nonlinier.

3.2 Kajian Terapan

Kajian terapan menggunakan data *inflow* dan *outflow* di empat lokasi KPw Bank Indonesia wilayah Jawa Timur menggunakan model GSTARX dengan variabel prediktor nonmetrik yaitu efek variasi kalender dan model *hybrid* GSTARX-ANN.

3.2.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam kajian terapan merupakan data sekunder *inflow* dan *outflow* uang kartal di Kota Surabaya, Malang, Kediri dan Jember yang diperoleh dari Bank Indonesia. Periode data yang diteliti dari bulan Januari 2003 sampai dengan Desember 2014, dengan periode data *in sample* yaitu Januari 2003 sampai dengan bulan Desember 2013 sedangkan data *out sample* mulai bulan Januari 2014 sampai dengan Desember 2014. Variabel prediktor yang digunakan dalam pemodelan terdiri dari beberapa variabel yaitu:

- i. Variabel untuk *dummy* tren dan kebijakan Bank Indonesia
 - t : tren kenaikan *inflow* atau *outflow* uang kartal dengan $t = 1, 2, \dots, n$.
 - $D_{i,t}$: *dummy* kebijakan Bank Indonesia yaitu kebijakan periode pertama bulan Januari 2007 hingga Desember 2010, kebijakan periode kedua bulan Januari 2011 hingga Desember 2014.
 - $tD_{i,t}$: tren dan kebijakan Bank Indonesia pada periode ke- i .

ii. Variabel *dummy* untuk pola musiman (bulan)

$$S_{1,t} = \begin{cases} 1, & \text{bulan Januari,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

$$S_{2,t} = \begin{cases} 1, & \text{bulan Februari,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

$$\vdots$$

$$S_{12,t} = \begin{cases} 1, & \text{bulan Desember,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

iii. Variabel *dummy* hari raya Idul Fitri

Diasumsikan efek hari raya Idul Fitri berkaitan dengan minggu terjadinya lebaran Idul Fitri satu bulan sebelumnya ($t-1$), bulan terjadinya Idul Fitri (t), dan satu bulan setelah lebaran Idul Fitri ($t+1$). Efek satu bulan sebelum lebaran Idul Fitri, yaitu

$$L_{1,t-1} = \begin{cases} 1, & \text{satu bulan sebelum Idul Fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

$$\vdots$$

$$L_{4,t-1} = \begin{cases} 1, & \text{satu bulan sebelum Idul Fitri yang terjadi pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Efek pada bulan Lebaran Idul Fitri, yaitu

$$L_{1,t} = \begin{cases} 1, & \text{bulan saat Idul Fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

$$\vdots$$

$$L_{4,t} = \begin{cases} 1, & \text{bulan saat Idul Fitri yang terjadi pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Efek satu bulan setelah lebaran Idul Fitri, yaitu

$$L_{1,t+1} = \begin{cases} 1, & \text{satu bulan sesudah Idul Fitri apabila pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

$$\vdots$$

$$L_{4,t+1} = \begin{cases} 1, & \text{satu bulan sesudah Idul Fitri apabila pada minggu ke-4,} \\ 0, & \text{bulan lainnya.} \end{cases}$$

Tanggal terjadinya hari Raya Idul Fitri disajikan pada Tabel 3.1 dan berikut ini adalah ketentuan minggu berdasarkan peraturan Bank Indonesia,

Minggu ke-1 : tanggal 1 sampai tanggal 7,
Minggu ke-2 : tanggal 8 sampai tanggal 15,
Minggu ke-3 : tanggal 16 sampai tanggal 23,
Minggu ke-4 : tanggal 24 sampai dengan tanggal terakhir pada bulan tersebut.

Tabel 3.1 Tanggal Hari Raya Idul Fitri

Tahun	Hari Raya Idul Fitri		
	Tanggal Hari Raya	Minggu terjadinya Hari Raya	
2003	25-26	November	Minggu ke-4
2004	14-15	November	Minggu ke-2
2005	3-4	November	Minggu ke-1
2006	23-24	Oktober	Minggu ke-4
2007	12-13	Oktober	Minggu ke-2
2008	1-2	Oktober	Minggu ke-1
2009	20-21	September	Minggu ke-3
2010	10-11	September	Minggu ke-2
2011	30-31	Agustus	Minggu ke-4
2012	19-20	Agustus	Minggu ke-3
2013	8-9	Agustus	Minggu ke-2
2014	28-29	Juli	Minggu ke-4

3.2.2 Struktur Data

Struktur data penelitian disajikan pada Tabel 3.2 untuk data *inflow* dan Tabel 3.3 untuk data *outflow*. Berdasarkan pengaruh variasi kalender, *inflow* cenderung tinggi satu bulan setelah lebaran Idul Fitri ($V_{i,t+1}$) sedangkan *outflow* cenderung tinggi satu bulan sebelum lebaran Idul Fitri ($V_{i,t-1}$).

Tabel 3.2 Struktur Data *Inflow* Metode GSTARX

Bulan-Tahun	<i>Inflow</i> $Z_{i,t}$	<i>Dummy</i>													
		t	Periode				Bulan				Variasi Kalender				
			$D_{1,t}$	$D_{2,t}$	$tD_{1,t}$	$tD_{2,t}$	$S_{1,t}$	$S_{2,t}$...	$S_{12,t}$	$V_{1,t}$	$V_{2,t}$...	$V_{3,t+1}$	$V_{4,t+1}$
Jan-03	$Z_{1,1}$	1	0	0	0	0	1	0	...	0	0	0	...	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-14	$Z_{1,144}$	144	0	1	0	144	0	0	...	1	0	0	...	0	0
Jan-03	$Z_{2,1}$	1	0	0	0	0	1	0	...	0	0	0	...	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-14	$Z_{2,144}$	144	0	1	0	144	0	0	...	1	0	0	...	0	0
Jan-03	$Z_{3,1}$	1	0	0	0	0	1	0	...	0	0	0	...	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-16	$Z_{3,144}$	144	0	1	0	144	0	0	...	1	0	0	...	0	0
Jan-03	$Z_{4,1}$	1	0	0	0	0	1	0	...	0	0	0	...	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-16	$Z_{4,144}$	144	0	1	0	144	0	0	...	1	0	0	...	0	0

Tabel 3.3 Struktur Data *Outflow* Metode GSTARX

Bulan-Tahun	<i>Outflow</i> $Z_{i,t}$	<i>Dummy</i>													
		t	Periode				Bulan				Variasi Kalender				
			$D_{1,t}$	$D_{2,t}$	$tD_{1,t}$	$tD_{2,t}$	$S_{1,t}$	$S_{2,t}$	\dots	$S_{12,t}$	$V_{1,t}$	$V_{2,t}$	\dots	$V_{3,t-1}$	$V_{4,t-1}$
Jan-03	$Z_{1,1}$	1	0	0	0	0	1	0	\dots	0	0	0	\dots	0	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
Des-14	$Z_{1,144}$	144	0	1	0	144	0	0	\dots	1	0	0	\dots	0	0
Jan-03	$Z_{2,1}$	1	0	0	0	0	1	0	\dots	0	0	0	\dots	0	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
Des-14	$Z_{2,144}$	144	0	1	0	144	0	0	\dots	1	0	0	\dots	0	0
Jan-03	$Z_{3,1}$	1	0	0	0	0	1	0	\dots	0	0	0	\dots	0	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
Des-14	$Z_{3,144}$	144	0	1	0	144	0	0	\dots	1	0	0	\dots	0	0
Jan-03	$Z_{4,1}$	1	0	0	0	0	1	0	\dots	0	0	0	\dots	0	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
Des-14	$Z_{4,144}$	144	0	1	0	144	0	0	\dots	1	0	0	\dots	0	0

3.2.3 Langkah Analisis

Berikut ini dijelaskan tahapan pembentukan model GSTARX dan model *hybrid* GSTARX-ANN.

a. Tahapan Pembentukan Model GSTARX

Tahapan dalam pembentukan model GSTARX pada data *inflow* dan *outflow* di empat lokasi KPw Bank Indonesia wilayah Jawa Timur sebagai berikut (secara visual disajikan pada Gambar 3.1).

I. Identifikasi Model

- Melakukan analisis deskriptif terhadap data *inflow* dan *outflow* di masing-masing KPw Bank Indonesia di Jawa Timur.
- Mengidentifikasi pola data *inflow* dan *outflow* di masing-masing KPw Bank Indonesia di Jawa Timur menggunakan *time series plot*.
- Menentukan variabel *dummy* yaitu *dummy* tren, periode kebijakan BI, musiman, dan efek variasi kalender.

II. Tahap 1: Pemodelan Pola Tren, Musiman, dan Variasi Kalender

- Mengestimasi secara serentak model variasi kalender, tren, dan musiman.

- ii. Membentuk model persamaan regresi yang akan diestimasi, untuk data *inflow*, model yang terbentuk adalah sebagai berikut

$$\begin{bmatrix} Z_{1,t} \\ Z_{2,t} \\ Z_{3,t} \\ Z_{4,t} \end{bmatrix} = \begin{bmatrix} \delta_{11}t + \delta_{12}D_{1,t} + \dots + \delta_{15}tD_{2,t} + \sum_{m=1}^{12} \gamma_{1m}S_{m,t} + \sum_{g=1}^4 \nu_{1g}V_{g,t} + \sum_{g=1}^4 \vartheta_{1g}V_{g,t+1} + N_{1,t} \\ \delta_{21}t + \delta_{22}D_{1,t} + \dots + \delta_{25}tD_{2,t} + \sum_{m=1}^{12} \gamma_{2m}S_{m,t} + \sum_{g=1}^4 \nu_{2g}V_{g,t} + \sum_{g=1}^4 \vartheta_{2g}V_{g,t+1} + N_{2,t} \\ \delta_{31}t + \delta_{32}D_{1,t} + \dots + \delta_{35}tD_{2,t} + \sum_{m=1}^{12} \gamma_{3m}S_{m,t} + \sum_{g=1}^4 \nu_{3g}V_{g,t} + \sum_{g=1}^4 \vartheta_{3g}V_{g,t+1} + N_{3,t} \\ \delta_{41}t + \delta_{42}D_{1,t} + \dots + \delta_{45}tD_{2,t} + \sum_{m=1}^{12} \gamma_{4m}S_{m,t} + \sum_{g=1}^4 \nu_{4g}V_{g,t} + \sum_{g=1}^4 \vartheta_{4g}V_{g,t+1} + N_{4,t} \end{bmatrix} \quad (3.7)$$

dengan δ_i merupakan parameter tren linier, $S_{1,t}, S_{2,t}, \dots, S_{12,t}$ merupakan variabel *dummy* musiman, dalam penelitian ini adalah bulan, $V_{1,t}, V_{2,t}, V_{3,t}, V_{4,t}$ adalah minggu ke-1 hingga minggu ke-4 pada bulan Idul Fitri, $V_{1,t+1}, V_{2,t+1}, V_{3,t+1}, V_{4,t+1}$ adalah minggu ke-1 hingga minggu ke-4 satu bulan setelah Idul Fitri.

Sedangkan untuk data *outflow*, model yang terbentuk adalah sebagai berikut

$$\begin{bmatrix} Z_{1,t} \\ Z_{2,t} \\ Z_{3,t} \\ Z_{4,t} \end{bmatrix} = \begin{bmatrix} \delta_{11}t + \delta_{12}D_{2,t} + \dots + \delta_{15}tD_{3,t} + \sum_{m=1}^{12} \gamma_{1m}S_{m,t} + \sum_{g=1}^4 \nu_{1g}V_{g,t} + \sum_{g=1}^4 \nu_{1g}V_{g,t-1} + N_{1,t} \\ \delta_{21}t + \delta_{22}D_{2,t} + \dots + \delta_{25}tD_{3,t} + \sum_{m=1}^{12} \gamma_{2m}S_{m,t} + \sum_{g=1}^4 \nu_{2g}V_{g,t} + \sum_{g=1}^4 \nu_{2g}V_{g,t-1} + N_{2,t} \\ \delta_{31}t + \delta_{32}D_{2,t} + \dots + \delta_{35}tD_{3,t} + \sum_{m=1}^{12} \gamma_{3m}S_{m,t} + \sum_{g=1}^4 \nu_{3g}V_{g,t} + \sum_{g=1}^4 \nu_{3g}V_{g,t-1} + N_{3,t} \\ \delta_{41}t + \delta_{42}D_{2,t} + \dots + \delta_{45}tD_{3,t} + \sum_{m=1}^{12} \gamma_{4m}S_{m,t} + \sum_{g=1}^4 \nu_{4g}V_{g,t} + \sum_{g=1}^4 \nu_{4g}V_{g,t-1} + N_{4,t} \end{bmatrix} \quad (3.8)$$

dengan $V_{1,t-1}, V_{2,t-1}, V_{3,t-1}, V_{4,t-1}$ adalah minggu ke-1 hingga minggu ke-4 satu bulan sebelum Idul Fitri.

- iii. Melakukan pengecekan signifikansi parameter dengan metode *backward*.
iv. Menghitung nilai residual $N_{i,t}$ data *inflow* dan *outflow*.


III. Tahap 2: Pemodelan GSTARX

- i. Melakukan pemeriksaan stasioneritas dari komponen $N_{i,t}$ yang diperoleh pada Tahap 1 dengan menggunakan MCCF.
ii. Identifikasi orde waktu, $AR(p)$ dari model $N_{i,t}$ yang telah stasioner dengan menggunakan MPCCF dan nilai AIC minimum.


- iii. Menentukan bobot spasial yang digunakan, bobot spasial yang digunakan ditentukan dengan orde spasial satu (p_1).
- iv. Melakukan perhitungan nilai pembobot lokasi ($\mathbf{W}^{(1)}$) menggunakan bobot seragam, invers jarak, dan normalisasi inferensia korelasi silang parsial.
- v. Melakukan estimasi parameter dengan model GSTARX

$$\mathbf{N}(t) = \sum_{k=1}^p \left(\Phi_{k0} \mathbf{N}(t-k) + \Phi_{k1} \mathbf{W}^{(1)} \mathbf{N}(t-k) \right) + \mathbf{a}(t).$$

- vi. Melakukan pengujian signifikansi parameter model GSTARX, jika terdapat parameter-parameter yang tidak signifikan, dilakukan *restricted* dengan metode *backward*.
 - vii. Mendapatkan model GSTARX.
- IV. Melakukan pengujian kebaikan model pada residual dengan menggunakan uji asumsi *white noise* dengan menggunakan nilai AIC minimum dan berdistribusi normal multivariat.
- V. Membandingkan hasil peramalan GSTARX dengan tiga macam bobot menggunakan kriteria model RMSE untuk data *in sample* dan *out sample*.
- VI. Mendapatkan model terbaik berdasarkan data *in sample* dan *out sample*.



Gambar 3.1 Tahapan Pembentukan Model GSTARX



Gambar 3.1 Tahapan Pembentukan Model GSTARX (lanjutan)

b. Tahapan Pembentukan Model *Hybrid* GSTARX-ANN

Melakukan pemodelan *hybrid* GSTARX-ANN dengan pembentukan model secara visual disajikan pada Gambar 3.2 untuk model *hybrid* GSTARX-FFNN dan Gambar 3.3 untuk model *hybrid* GSTARX-DLNN sebagai berikut:

- i. Tahap pertama dilakukan pemodelan *time series regression* (TSR) dengan variabel prediktor berupa tren, musiman, dan variasi kalender, sebagai *preprocessing* data. Persamaan model tahap pertama seperti persamaan (3.7) untuk data *inflow* dan (3.8) persamaan untuk data *outflow*.
- ii. Kemudian melakukan perhitungan residual model TSR dan dilakukan pembobotan lokasi pada residual model TSR. *Output* merupakan suatu vektor yang terdiri dari residual model TSR di empat lokasi.

Persamaan tahap kedua untuk model GSTARX-FFNN sebagai berikut:

Persamaan pada *output layer*

$$\hat{\mathbf{N}}_t = b^o + v_1 f(x_1) + v_2 f(x_2) + \dots + v_m f(x_m). \quad (3.9)$$

Persamaan pada *hidden layer*

$$f(x_i) = b_i^1 + w_{1i} f(\mathbf{N}_{1,t-1}) + w_{2i} f(\mathbf{N}_{2,t-1}) + \dots + w_{pi} f(\mathbf{W}_{4,t-1}). \quad (3.10)$$

Persamaan tahap kedua untuk model GSTARX-DLNN sebagai berikut:

Persamaan pada *output layer*

$$\hat{\mathbf{N}}_t = b^o + v_1 f^{h_2}(x_1) + v_2 f^{h_2}(x_2) + \dots + v_m f^{h_2}(x_m). \quad (3.11)$$

Persamaan pada *hidden layer* kedua


$$f^{h_2}(x_i) = b_i^1 + v_{1i} f^{h_1}(x_1) + v_{2i} f^{h_1}(x_2) + \dots + v_{pi} f^{h_1}(x_m). \quad (3.12)$$

Persamaan pada *hidden layer* pertama


$$f^h(x_i) = b_i^2 + w_{1i}f(\mathbf{N}_{1,t-1}) + w_{2i}f(\mathbf{N}_{2,t-1}) + \dots + w_{pi}f(\mathbf{W}_{4,t-1}). \quad (3.13)$$

- iii. Tahap akhir dari pemodelan *hybrid* GSTARX-ANN adalah memilih arsitektur terbaik menggunakan kriteria evaluasi model RMSE dan MAPE.

Setelah dilakukan pemodelan menggunakan GSTARX dan *hybrid* GSTARX-ANN, dilakukan pemilihan model terbaik berdasarkan nilai RMSE dan MAPE terkecil untuk menentukan model terbaik dan melakukan peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia wilayah Jawa Timur berdasarkan model terbaik yang diperoleh.



Gambar 3.2 Flowchart Pemodelan Hybrid GSTARX-FFNN



Gambar 3.3 Flowchart Pemodelan Hybrid GSTARX-DLNN

dengan, $\mathbf{N}_{i,t-1}$ merupakan lag-1 residual model TSR dan $\mathbf{W}_{i,t-1}$ merupakan lag-1 residual model TSR yang sudah terboboti.

3.3 Syntax SAS Pemodelan VARX dan GSTARX

Berikut ini ditampilkan *syntax* SAS GSTARX untuk data simulasi dengan estimasi parameter pemodelan tahap I dan tahap II menggunakan GLS.

Tabel 3.4 *Syntax* SAS Pemodelan VARX dan GSTARX

```
data simulasi;
  input Z1 Z2 Z3 t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1 V3t1
    V4t1;
datalines;
21.86788576 25.66443467 16.00463076 1 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
.
.
.
52.75963176 60.45156365 53.59882508 180 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
;

/*-----Pemodelan Tahap I, Pola Tren, Musiman, dan Variasi Kalender-----*/
proc syslin data=simulasi out=resiTSR sur;
  Z1:  model Z1 = t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
        V3t1 V4t1 / noint;
        output p=zhat1 r=zresid1;
  Z2:  model Z2 = t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
        V3t1 V4t1 / noint;
        output p=zhat2 r=zresid2;
  Z3:  model Z3 = t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
        V3t1 V4t1 / noint;
        output p=zhat3 r=zresid3;
run;

/*-----Pemodelan Residual Tahap I dengan VAR-----*/
proc varmax data=resiTSR printall;
  model zresid1 zresid2 zresid3/ p=1 noint minic= (p=5 q=5);
  restrict AR(1,1,3)=0, AR(1,2,1)=0, AR(1,2,3)=0, AR(1,3,1)=0;
  output lead=12 out=hasilVARX;
run;
proc export data=work.hasilVARX
  outfile='D:\VARXskenario1simul1.xls'
  dbms=excel
  replace;
run;

/*-----Pemodelan Residual Tahap I dengan GSTAR Bobot Seragam-----*/
data resiTSR;
  set resiTSR;
  lagresi1 = lag(zresid1);
  lagresi2 = lag(zresid2);
  lagresi3 = lag(zresid3);
  w1= .5*(lagresi2+lagresi3);
  w2= .5*(lagresi1+lagresi3);
  w3= .5*(lagresi1+lagresi2);
proc syslin data=resiTSR sur out=HASILGSTARX;
  e1t:  model zresid1= lagresi1 w1/ noint;
        output p=ehat1 r=eresid1;
  e2t:  model zresid2= lagresi2 w2/ noint;
        output p=ehat2 r=eresid2;
  e3t:  model zresid3= lagresi3 w3/ noint;
        output p=ehat3 r=eresid3;
run;
proc export data=work.HASILGSTARX
  outfile='D:\GSTARXskenario1simul1.xls'
  dbms=excel
  replace;
run;
```

BAB 4


ANALISIS DAN PEMBAHASAN

Pada bab ini dibahas hasil analisis dari data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* yang linier maupun nonlinier untuk mengetahui kebaikan model *hybrid* GSTARX-ANN dalam meramalkan data *space time*. Selain itu, juga dibahas hasil analisis dari data *inflow* dan *outflow* uang kartal di Kota Surabaya, Malang, Kediri dan Jember menggunakan GSTARX dan *hybrid* GSTARX-ANN.

4.1 Pemodelan Data Simulasi

Untuk mengetahui kebaikan model *hybrid* GSTARX-ANN dalam meramalkan data *space time* yang mengandung komponen tren, musiman, variasi kalender, serta deret *noise* linier maupun nonlinier maka dilakukan studi simulasi. Kriteria kebaikan model yang digunakan pada studi simulasi adalah RMSE. Data yang digunakan adalah simulasi data *outflow* periode bulan Januari 2001 sampai Desember 2015 sebagai data *in sample* dan periode Januari 2016 sampai Desember 2016 sebagai data *out sample*.


Data $Z_t^{(i)}$ didapatkan berdasarkan persamaan (3.1). Untuk mendapatkan masing-masing komponen sesuai dengan persamaan (3.2)-(3.6). Berikut adalah plot komponen tren dan musiman.



Gambar 4.1 Plot Komponen (a) Tren dan (b) Musiman

Berdasarkan Gambar 4.1 (a) terlihat bahwa dengan adanya pola tren mengakibatkan kenaikan data seiring pertambahan waktu. Pola musiman homogen, Gambar 4.1 (b), mengakibatkan pada bulan yang sama, data cenderung

memiliki nilai yang sama. Efek variasi kalender yang disajikan pada Gambar 4.2, menyebabkan pola data benilai tinggi pada waktu-waktu terjadinya variasi kalender, dalam penelitian ini efek hari raya Idul Fitri.



Gambar 4.2 Plot Komponen Variasi Kalender

Penentuan efek variasi kalender disesuaikan dengan data *outflow* uang kartal di KPw Bank Indonesia wilayah Jawa Timur, dimana, jika hari raya Idul Fitri terjadi pada minggu I atau minggu II, maka kecenderungannya *outflow* tinggi pada satu bulan sebelum terjadinya hari raya Idul Fitri. Sedangkan, jika hari raya Idul Fitri terjadi pada minggu III atau minggu IV, maka *outflow* tinggi pada bulan terjadinya hari raya Idul Fitri. Studi simulasi pada penelitian ini menggunakan dua skenario. Skenario I, *noise* merupakan deret yang belum *white noise* dan berpola linier. Sedangkan skenario II, *noise* merupakan deret yang belum *white noise* dan berpola nonlinier.

4.1.1 Pemodelan Data Simulasi Skenario I


Pada skenario I, deret *noise* merupakan deret yang belum *white noise* yang mengikuti model GSTAR(1₁). Koefisien parameter yang digunakan dalam model GSTAR(1₁) sudah sesuai dengan syarat stasioner parameter GSTAR, yaitu nilai eigen parameter kurang dari 1, $|\lambda \mathbf{I} - \Phi| = 0$, $|\Phi| = |\lambda \mathbf{I}|$, dengan $|\lambda_i| < 1$. Parameter yang digunakan tersebut dapat dilihat pada persamaan matriks berikut

$$\Phi_1 = \begin{bmatrix} 0,45 & 0,25 & 0,25 \\ 0,15 & 0,40 & 0,15 \\ 0,20 & 0,20 & 0,35 \end{bmatrix}.$$

Pada skenario I, residual antar lokasi saling berkorelasi, dengan matriks varians kovarians yaitu Σ dan *mean* $\mathbf{0}$. Matriks varians kovarians residual pada skenario I sebagai berikut

$$\Sigma = \begin{bmatrix} 1,00 & 0,65 & 0,60 \\ 0,65 & 1,00 & 0,55 \\ 0,60 & 0,55 & 1,00 \end{bmatrix}.$$

Selanjutnya, ditampilkan identifikasi deret *noise* melalui matriks plot antara *noise* pada waktu ke- t dengan *noise* pada waktu ke $t-1$ di tiga lokasi yang ditunjukkan pada Gambar 4.3.




Gambar 4.3 Matriks Plot Deret *Noise* Linier di Tiga Lokasi

Berdasarkan matriks plot yang terbentuk pada Gambar 4.3 terlihat bahwa hubungan antara deret *noise* pada waktu ke- t dengan deret *noise* pada waktu ke $t-1$ antar lokasi berpola linier. Setelah dibangkitkan data simulasi $Z_t^{(i)}$ sesuai dengan persamaan (3.1) dengan replikasi sebanyak 10 kali, dilakukan pemodelan secara dua tahap, kemudian dihitung akurasi ramalan dengan kriteria kebaikan model RMSE. Berikut adalah pembahasan pemodelan simulasi skenario I.

a. Pemodelan Tahap Pertama Data Simulasi Skenario I

Tahap pertama dilakukan pemodelan pola tren, musiman, dan variasi kalender menggunakan *time series regression* dengan metode estimasi yaitu *Generalized Least Square* (GLS) dikarenakan residual model cenderung

berkorelasi antar lokasi, sehingga jika menggunakan OLS menghasilkan estimator yang tidak efisien.



Gambar 4.4 Plot *Time Series* Data Simulasi 1 di Tiga Lokasi

Gambar 4.4 merupakan *time series plot* data simulasi 1 skenario I di tiga lokasi, yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* mengikuti pola linier. Selanjutnya, hasil estimasi parameter tahap pertama disajikan pada Tabel 4.1.

Tabel 4.1 Koefisien Parameter Tahap I pada Data Simulasi 1

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
1	$\delta^{(1)}$	0,21	0,205	0,003	0,200	0,210	Benar
	$\gamma_1^{(1)}$	22,00	21,940	0,509	20,943	22,937	Benar
	$\gamma_2^{(1)}$	24,00	24,115	0,510	23,115	25,114	Benar
	$\gamma_3^{(1)}$	27,00	26,945	0,511	25,943	27,947	Benar
	$\gamma_4^{(1)}$	24,00	23,793	0,512	22,789	24,797	Benar
	$\gamma_5^{(1)}$	22,00	21,741	0,513	20,735	22,748	Benar
	$\gamma_6^{(1)}$	17,00	16,820	0,521	15,800	17,840	Benar
	$\gamma_7^{(1)}$	13,00	12,593	0,534	11,546	13,640	Benar
	$\gamma_8^{(1)}$	10,00	9,495	0,535	8,446	10,544	Benar
	$\gamma_9^{(1)}$	6,00	5,518	0,542	4,456	6,580	Benar

Tabel 4.1 Koefisien Parameter Tahap I pada Data Simulasi 1 (lanjutan)

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
1	$\gamma_{10}^{(1)}$	10,00	9,417	0,554	8,331	10,502	Benar
	$\gamma_{11}^{(1)}$	13,00	13,002	0,549	11,925	14,078	Benar
	$\gamma_{12}^{(1)}$	17,00	17,166	0,532	16,123	18,209	Benar
	$\nu_1^{(1)}$	32,00	30,339	1,072	28,237	32,440	Benar
	$\nu_2^{(1)}$	43,00	43,534	0,929	41,713	45,355	Benar
	$\nu_3^{(1)}$	47,00	46,905	0,926	45,089	48,721	Benar
	$\nu_4^{(1)}$	49,00	50,015	0,929	48,194	51,835	Benar
	$\nu_1^{(1)}$	50,00	49,813	1,075	47,706	51,921	Benar
	$\nu_2^{(1)}$	46,00	47,431	0,929	45,610	49,252	Benar
	$\nu_3^{(1)}$	39,00	38,528	0,926	36,712	40,343	Benar
	$\nu_4^{(1)}$	34,00	34,768	0,926	32,953	36,584	Benar
2	$\delta^{(2)}$	0,23	0,229	0,002	0,225	0,233	Benar
	$\gamma_1^{(2)}$	25,00	24,794	0,382	24,046	25,542	Benar
	$\gamma_2^{(2)}$	28,00	27,736	0,383	26,987	28,486	Benar
	$\gamma_3^{(2)}$	30,00	29,420	0,383	28,669	30,172	Benar
	$\gamma_4^{(2)}$	28,00	27,422	0,384	26,669	28,175	Benar
	$\gamma_5^{(2)}$	25,00	24,918	0,385	24,163	25,673	Benar
	$\gamma_6^{(2)}$	21,00	20,670	0,391	19,905	21,435	Benar
	$\gamma_7^{(2)}$	16,00	15,429	0,401	14,644	16,214	Benar
	$\gamma_8^{(2)}$	13,00	12,624	0,402	11,837	13,412	Benar
	$\gamma_9^{(2)}$	9,00	8,689	0,407	7,892	9,486	Benar
	$\gamma_{10}^{(2)}$	13,00	12,868	0,415	12,054	13,682	Benar
	$\gamma_{11}^{(2)}$	16,00	15,914	0,412	15,107	16,722	Benar
	$\gamma_{12}^{(2)}$	21,00	21,030	0,399	20,247	21,812	Benar
	$\nu_1^{(2)}$	45,00	43,751	0,804	42,175	45,328	Benar
	$\nu_2^{(2)}$	49,00	49,225	0,697	47,859	50,591	Benar
	$\nu_3^{(2)}$	55,00	54,294	0,695	52,931	55,656	Benar
	$\nu_4^{(2)}$	57,00	58,062	0,697	56,697	59,428	Benar
	$\nu_1^{(2)}$	60,00	59,356	0,807	57,775	60,937	Benar
	$\nu_2^{(2)}$	54,00	54,725	0,697	53,359	56,092	Benar
	$\nu_3^{(2)}$	44,00	43,388	0,695	42,026	44,750	Benar
	$\nu_4^{(2)}$	36,00	36,338	0,695	34,976	37,700	Benar
3	$\delta^{(3)}$	0,24	0,236	0,002	0,232	0,240	Benar
	$\gamma_1^{(3)}$	17,00	17,025	0,404	16,233	17,817	Benar
	$\gamma_2^{(3)}$	21,00	21,184	0,405	20,391	21,978	Benar

Tabel 4.1 Koefisien Parameter Tahap I pada Data Simulasi 1 (lanjutan)

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
3	$\gamma_3^{(3)}$	24,00	23,916	0,406	23,121	24,712	Benar
	$\gamma_4^{(3)}$	21,00	20,959	0,407	20,161	21,756	Benar
	$\gamma_5^{(3)}$	17,00	16,906	0,408	16,107	17,705	Benar
	$\gamma_6^{(3)}$	12,00	11,820	0,413	11,009	12,630	Benar
	$\gamma_7^{(3)}$	9,00	8,802	0,424	7,971	9,633	Benar
	$\gamma_8^{(3)}$	6,00	5,426	0,425	4,592	6,259	Benar
	$\gamma_9^{(3)}$	4,00	3,354	0,430	2,511	4,198	Benar
	$\gamma_{10}^{(3)}$	6,00	5,674	0,440	4,812	6,536	Benar
	$\gamma_{11}^{(3)}$	9,00	9,229	0,436	8,375	10,084	Benar
	$\gamma_{12}^{(3)}$	12,00	12,238	0,423	11,410	13,067	Benar
	$\nu_1^{(3)}$	37,00	36,386	0,851	34,717	38,054	Benar
	$\nu_2^{(3)}$	40,00	40,679	0,738	39,233	42,124	Benar
	$\nu_3^{(3)}$	47,00	46,988	0,735	45,547	48,430	Benar
	$\nu_4^{(3)}$	51,00	51,599	0,737	50,154	53,045	Benar
	$\nu_1^{(3)}$	49,00	48,854	0,854	47,181	50,528	Benar
	$\nu_2^{(3)}$	47,00	47,657	0,738	46,212	49,103	Benar
	$\nu_3^{(3)}$	41,00	40,889	0,735	39,447	42,330	Benar
	$\nu_4^{(3)}$	37,00	37,573	0,735	36,131	39,014	Benar

Berdasarkan hasil taksiran interval 95% dari setiap koefisien parameter yang diestimasi, semua parameter yang diestimasi sudah memberikan hasil yang benar. Dapat diketahui dari selang kepercayaan 95% parameter yang diestimasi sudah memuat nilai parameter yang sebenarnya. Semua parameter yang diestimasi pada tahap pertama sudah signifikan (ditampilkan pada Lampiran 1-10) sehingga didapatkan model persamaan tahap pertama sebagai berikut

$$\begin{aligned}
Z_t^{(1)} = & 0,205t + 21,94S_{1,t} + 24,115S_{2,t} + 26,945S_{3,t} + 23,793S_{4,t} + 21,741S_{5,t} + \\
& 16,82S_{6,t} + 12,593S_{7,t} + 9,495S_{8,t} + 5,518S_{9,t} + 9,417S_{10,t} + 13,002S_{11,t} + \\
& 17,166S_{12,t} + 30,339V_{1,t} + 43,534V_{2,t} + 46,905V_{3,t} + 50,015V_{4,t} + \\
& 49,813V_{1,t-1} + 47,431V_{2,t-1} + 38,528V_{3,t-1} + 34,768V_{4,t-1} + N_{1,t}.
\end{aligned} \tag{4.1}$$

$$\begin{aligned}
Z_t^{(2)} = & 0,229t + 24,794S_{1,t} + 27,736S_{2,t} + 29,42S_{3,t} + 27,422S_{4,t} + 24,918S_{5,t} + \\
& 20,67S_{6,t} + 15,429S_{7,t} + 12,624S_{8,t} + 8,689S_{9,t} + 12,868S_{10,t} + 15,914S_{11,t} + \\
& 21,03S_{12,t} + 43,751V_{1,t} + 49,225V_{2,t} + 54,294V_{3,t} + 58,062V_{4,t} + 59,356V_{1,t-1} + \\
& 54,725V_{2,t-1} + 43,388V_{3,t-1} + 36,338V_{4,t-1} + N_{2,t}.
\end{aligned} \tag{4.2}$$

$$\begin{aligned}
Z_t^{(3)} = & 0,236t + 17,025S_{1,t} + 21,184S_{2,t} + 23,916S_{3,t} + 20,959S_{4,t} + 16,906S_{5,t} + \\
& 11,82S_{6,t} + 8,802S_{7,t} + 5,426S_{8,t} + 3,354S_{9,t} + 5,674S_{10,t} + 9,229S_{11,t} + \\
& 12,238S_{12,t} + 36,386V_{1,t} + 40,679V_{2,t} + 46,988V_{3,t} + 51,599V_{4,t} + \\
& 48,854V_{1,t-1} + 47,657V_{2,t-1} + 40,889V_{3,t-1} + 37,573V_{4,t-1} + N_{3,t}.
\end{aligned} \tag{4.3}$$

Persamaan (4.1)–(4.3) dapat disajikan dalam bentuk matriks sebagai berikut

$$\begin{aligned}
\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \end{bmatrix} = & \begin{bmatrix} 0,205 & 0 & 0 \\ 0 & 0,229 & 0 \\ 0 & 0 & 0,236 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \end{bmatrix} + \begin{bmatrix} 21,94 & 0 & 0 \\ 0 & 24,794 & 0 \\ 0 & 0 & 17,025 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \\
& \begin{bmatrix} 38,528 & 0 & 0 \\ 0 & 43,388 & 0 \\ 0 & 0 & 40,889 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 34,768 & 0 & 0 \\ 0 & 36,338 & 0 \\ 0 & 0 & 37,573 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix}.
\end{aligned}$$


Selanjutnya akan dibahas pemodelan tahap kedua data simulasi skenario I dengan menggunakan VAR, GSTAR, dan *hybrid* GSTAR-ANN.

b. Pemodelan Tahap Kedua Data Simulasi Skenario I

Tahap kedua dilakukan pemodelan residual tahap pertama menggunakan metode VAR, GSTAR, dan *hybrid* GSTAR-ANN. Pada pemodelan *hybrid* GSTAR-ANN, banyaknya *hidden layer* yang digunakan adalah 1 *hidden layer* dikenal dengan *feedforward neural network* (FFNN) dan 2 *hidden layer* yang sudah termasuk dalam kelompok *deep learning neural network* (DLNN). Berikut adalah pembahasan masing-masing metode pada pemodelan tahap kedua data simulasi skenario I.

Pemodelan Tahap Kedua Menggunakan VAR

Langkah awal dalam pemodelan VAR adalah melakukan identifikasi data simulasi di ketiga lokasi. Identifikasi ini bertujuan untuk mengetahui apakah data yang digunakan sudah stasioner atau tidak. Proses identifikasi stasioneritas secara visual dengan melihat *time series plot* yang ditampilkan pada Gambar 4.5. Selain itu, identifikasi stasioneritas juga dapat dilihat berdasarkan skematik MCCF. Berdasarkan Gambar 4.5, *time series plot* residual dari ketiga lokasi diduga sudah stasioner karena berada disekitar $\mu=0$.



Gambar 4.5 Time Series Plot Residual Tahap Pertama Data Simulasi 1 Skenario I

Kemudian dilakukan pemeriksaan stasioneritas melalui skematik MCCF dan pemeriksaan orde waktu (Ar) melalui skematik MPPCF dan nilai AIC sebagai berikut

Variable/ Lag	Schematic Representation of Cross Correlations												
	0	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	+++	+++	+++	+++	+++	+++	+++	+.+	+..	---
zresid2	+++	+++	+++	+++	+++	+++	+++	+.+	+..
zresid3	+++	+++	+++	+++	+++	+++	+++	+.+	+++-

Gambar 4.6 Representasi Skematik MCCF Residual Data Simulasi 1 Skenario I

Berdasarkan Gambar 4.6 menunjukkan bahwa data sudah stasioner terlihat dari skema MCCF yang cenderung turun cepat (*dies down*). Selanjutnya adalah melakukan identifikasi untuk menentukan orde dari model VAR dengan melihat skema MPCCF.

Variable/ Lag	Schematic Representation of Partial Cross Correlations											
	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	+..	-..-	...
zresid2	++-
zresid3	+.++-

Gambar 4.7 Representasi Skematik MPCCF Residual Data Simulasi 1 Skenario I

Berdasarkan skema MPCCF yang signifikan pada lag 1, sehingga model dugaan adalah VAR(1). Selain melakukan pengecekan melalui plot MPCCF,

perlu dilakukan pengecekan terhadap nilai AIC terkecil dari model yang disajikan pada Tabel 4.2.

Tabel 4.2 Nilai AIC Model VAR Residual Simulasi 1 Skenario I

Lag	MA 0	MA 1	MA 2	MA 3
AR 0	-0,4713	-0,7257	-0,9029	-1,0141
AR 1	-1,5051	-1,3994	-1,3724	-1,2862
AR 2	-1,4708	-1,3522	-1,3073	-1,2532
AR 3	-1,4029	-1,3100	-1,2199	-1,1693

Pada Tabel 4.2 menunjukkan bahwa nilai AIC terkecil dari model VAR adalah terletak di lag MA 0 dan AR 1 sehingga model yang diperoleh adalah benar model VAR(1).

Hasil estimasi parameter model VAR(1) memiliki 9 parameter. Akan tetapi, jika dilihat dari nilai *P-value* masing-masing parameter dapat diketahui bahwa tidak semua parameter memiliki pengaruh yang signifikan terhadap model. Untuk mengatasi adanya parameter yang tidak signifikan, maka dilakukan *restrict* terhadap parameter tersebut. Perintah *restrict* dilakukan terhadap satu demi satu variabel yang tidak signifikan secara bertahap, sampai semua parameter signifikan. Model yang digunakan adalah *full model* (melibatkan semua parameter tanpa memperhatikan signifikansinya) dan *restricted model* (parameter yang digunakan adalah yang signifikan). Menurut Armstrong (2001) dalam *forecasting* dapat menggunakan semua variabel untuk keperluan meningkatkan akurasi ramalan. Sehingga alasan penggunaan *full model* adalah untuk mengetahui apakah model ini dapat menghasilkan ramalan yang lebih baik dibandingkan *restricted model*. Berikut hasil estimasi parameter dari *full model* VAR(1).

Tabel 4.3 Estimasi Parameter *Full Model* VAR(1)

Lokasi	Parameter	Estimasi	Standar Error	t-value	P-value	Variabel
1	ϕ_{11}^1	0,409	0,099	4,12	0,0001	$N_{t-1}^{(1)}$
	ϕ_{12}^1	0,385	0,110	3,50	0,0006	$N_{t-1}^{(2)}$
	ϕ_{13}^1	0,181	0,116	1,56	0,1202	$N_{t-1}^{(3)}$
2	ϕ_{21}^1	0,138	0,089	1,55	0,1239	$N_{t-1}^{(1)}$
	ϕ_{22}^1	0,458	0,099	4,63	0,0001	$N_{t-1}^{(2)}$
	ϕ_{23}^1	0,074	0,104	0,71	0,4790	$N_{t-1}^{(3)}$
3	ϕ_{31}^1	0,112	0,094	1,19	0,2363	$N_{t-1}^{(1)}$
	ϕ_{32}^1	0,212	0,104	2,03	0,0435	$N_{t-1}^{(2)}$
	ϕ_{33}^1	0,386	0,110	3,52	0,0006	$N_{t-1}^{(3)}$

Berdasarkan *full model* maka dapat dibentuk persamaan matematis model VARX(1) dalam bentuk matriks seperti berikut

Persamaan tahap I

$$\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,205 & 0 & 0 \\ 0 & 0,229 & 0 \\ 0 & 0 & 0,236 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \end{bmatrix} + \begin{bmatrix} 21,94 & 0 & 0 \\ 0 & 24,794 & 0 \\ 0 & 0 & 17,025 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 38,53 & 0 & 0 \\ 0 & 43,39 & 0 \\ 0 & 0 & 40,89 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 34,768 & 0 & 0 \\ 0 & 36,338 & 0 \\ 0 & 0 & 37,573 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix}.$$

Persamaan tahap II

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,409 & 0,385 & 0,181 \\ 0,138 & 0,458 & 0,074 \\ 0,112 & 0,212 & 0,386 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}.$$

Hasil estimasi parameter dari model VAR(1) yang telah dilakukan *restricted* selengkapnya ditunjukkan pada Tabel 4.4.

Tabel 4.4 Estimasi Parameter Model VAR(1) Setelah Di-restrict

Lokasi	Parameter	Estimasi	Standar Error	t-value	P-value	Variabel
1	ϕ_{11}^1	0,357	0,055	6,52	0,0001	$N_{t-1}^{(1)}$
	ϕ_{12}^1	0,591	0,086	6,89	0,0001	$N_{t-1}^{(2)}$
2	ϕ_{22}^1	0,668	0,055	12,06	0,0001	$N_{t-1}^{(2)}$
3	ϕ_{32}^1	0,403	0,077	5,22	0,0001	$N_{t-1}^{(2)}$
	ϕ_{33}^1	0,302	0,061	4,95	0,0001	$N_{t-1}^{(3)}$

Berdasarkan parameter yang signifikan maka dapat dibentuk persamaan matematis tahap II model VAR(1) dalam bentuk matriks sebagai berikut


$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,357 & 0,591 & 0 \\ 0 & 0,668 & 0 \\ 0 & 0,403 & 0,302 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}.$$

Selanjutnya, untuk mengetahui kebaikan model VARX dalam meramalkan data simulasi pada skenario I, dihitung nilai RMSE *in sample* maupun *out sample* yang disajikan pada Tabel 4.5.


Tabel 4.5 Nilai Kebaikan Model VARX *All* dan *Restricted* Model pada Skenario I

Model	Data	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
<i>Full Model</i>	Simulasi 1	1,024	0,920	0,970	3,204	2,189	2,517
	Simulasi 2	0,925	0,944	0,990	1,820	1,297	1,354
	Simulasi 3	1,018	1,026	0,961	1,441	1,037	1,485
	Simulasi 4	0,935	0,983	1,035	1,459	1,181	1,313
	Simulasi 5	1,011	0,970	0,950	0,890	0,959	0,905
	Simulasi 6	0,979	1,022	0,995	1,881	1,534	1,785
	Simulasi 7	1,001	0,907	0,952	1,027	1,215	0,750
	Simulasi 8	0,968	0,855	0,993	1,007	0,995	0,828
	Simulasi 9	0,913	0,918	0,897	1,148	0,805	1,023
	Simulasi 10	1,019	0,967	0,939	0,956	1,071	1,502
<i>Restricted Model</i>	Simulasi 1	1,041	0,937	0,984	3,227	2,214	2,526
	Simulasi 2	0,939	0,958	0,999	1,848	1,308	1,375
	Simulasi 3	1,044	1,044	0,994	1,469	1,046	1,486
	Simulasi 4	0,941	0,992	1,069	1,463	1,211	1,280
	Simulasi 5	1,019	0,978	0,950	0,891	0,960	0,906
	Simulasi 6	0,992	1,036	1,003	1,884	1,535	1,789
	Simulasi 7	1,018	0,925	0,976	1,043	1,240	0,755
	Simulasi 8	0,973	0,855	0,997	1,029	0,992	0,839
	Simulasi 9	0,913	0,921	0,898	1,148	0,808	1,022
	Simulasi 10	1,033	0,994	0,954	0,977	1,131	1,520

Berdasarkan Tabel 4.5 hasil ramalan dengan menggunakan *full model* memberikan hasil ramalan yang lebih baik dibandingkan dengan menggunakan *restricted model*. Berikut ini adalah *time series plot* hasil ramalan di tiga lokasi untuk data simulasi 1 menggunakan *full model* VARX(1).



Gambar 4.8 *Time Series Plot* Data Aktual dan Ramalan *Full Model* VARX(1) Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3



Gambar 4.8 Time Series Plot Data Aktual dan Ramalan *Full Model* VARX(1) Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3 (lanjutan)

Berdasarkan Gambar 4.8, *time series plot* ramalan *in sample* maupun *out sample* data simulasi 1 di tiga lokasi, (a) untuk lokasi 1, (b) untuk lokasi 2, dan (c) untuk lokasi 3, terlihat sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender.


Pemodelan Tahap Kedua Menggunakan GSTAR

Dalam pemodelan GSTAR, orde model yang digunakan adalah sama dengan orde VAR sebelumnya, yaitu GSTAR(1₁). Bobot yang digunakan dalam pemodelan GSTAR yaitu bobot seragam dengan mengasumsikan bahwa setiap lokasi bersifat homogen. Estimasi parameter yang digunakan dalam pemodelan adalah GLS sama halnya dengan pemodelan tahap pertama. Hasil estimasi parameter model GSTAR(1₁) pada tahap kedua disajikan pada Tabel 4.6.


Tabel 4.6 Koefisien Parameter Tahap Dua Model GSTAR Simulasi 1

Parameter	Koefisien		SE	CI 95%		Keterangan
	Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
ϕ_{10}^1	0,45	0,411	0,069	0,276	0,545	Benar
ϕ_{20}^1	0,40	0,394	0,076	0,245	0,542	Benar
ϕ_{30}^1	0,35	0,451	0,075	0,304	0,599	Benar
ϕ_{11}^1	0,50	0,555	0,097	0,365	0,745	Benar
ϕ_{21}^1	0,30	0,271	0,069	0,137	0,406	Benar
ϕ_{31}^1	0,40	0,248	0,075	0,100	0,395	Salah

Tabel 4.6 menunjukkan bahwa hasil estimasi tahap kedua model GSTAR hanya satu parameter yang tidak sesuai dengan nilai parameter yang sebenarnya. Selanjutnya akan diperlihatkan taksiran parameter GSTAR data simulasi dengan replikasi sebanyak 10 kali untuk melihat konsistensi hasil estimasi. Nilai koefisien setiap parameter seperti persamaan (3.5).



Gambar 4.9 Koefisien Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Model GSTAR setiap Replikasi Data Simulasi (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3



Gambar 4.9 Koefisien Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Model GSTAR setiap Replikasi Data Simulasi (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3 (lanjutan)

Pada Gambar 4.9, dari hasil replikasi sebanyak 10 kali, terlihat bahwa secara umum nilai koefisien hasil estimasi parameter model GSTAR sudah baik, hal ini terlihat dari tidak lebih dari 2 replikasi yang tidak benar dengan nilai parameter sebenarnya (garis biru), bahkan untuk lokasi 1 semua parameter sudah sesuai dengan nilai sebenarnya. Seperti diketahui, dalam studi simulasi menggunakan konsep *trial and error*, inilah yang menyebabkan ada replikasi yang memuat parameter yang berbeda.

Parameter yang diestimasi sudah signifikan (ditampilkan pada Lampiran 1-10), sehingga secara lengkap model GSTARX(1₁) data simulasi 1 dapat dituliskan dalam bentuk matriks sebagai berikut


Persamaan tahap I

$$\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,205 & 0 & 0 \\ 0 & 0,229 & 0 \\ 0 & 0 & 0,236 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \end{bmatrix} + \begin{bmatrix} 21,94 & 0 & 0 \\ 0 & 24,794 & 0 \\ 0 & 0 & 17,025 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 38,53 & 0 & 0 \\ 0 & 43,39 & 0 \\ 0 & 0 & 40,89 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 34,768 & 0 & 0 \\ 0 & 36,338 & 0 \\ 0 & 0 & 37,573 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix}.$$

Persamaan tahap II

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,411 & 0,277 & 0,277 \\ 0,135 & 0,394 & 0,135 \\ 0,124 & 0,124 & 0,451 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}.$$

Selanjutnya adalah melakukan peramalan data simulasi 1 di ketiga lokasi menggunakan GSTARX(1₁). Hasil ramalan di ketiga lokasi ditampilkan dalam bentuk plot *time series*, seperti ditunjukkan pada Gambar 4.10.



Gambar 4.10 *Time Series Plot Data Aktual dan Ramalan GSTARX Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3*


Time series plot ramalan in sample maupun *out sample* data simulasi 1 di tiga lokasi, (a) untuk lokasi 1, (b) untuk lokasi 2, dan (c) untuk lokasi 3, terlihat sudah mengikuti pola data simulasi. Selanjutnya, untuk mengetahui kebaikan model GSTARX dalam meramalkan data simulasi pada skenario I, dihitung nilai RMSE *in sample* maupun *out sample* yang disajikan pada Tabel 4.7.

Tabel 4.7 Nilai Keباian Model GSTARX pada Skenario I

Data	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
Simulasi 1	1,028	0,921	0,973	2,084	1,386	1,658
Simulasi 2	0,925	0,944	0,991	1,434	1,447	1,261
Simulasi 3	1,020	1,028	0,961	1,190	0,806	1,037
Simulasi 4	0,936	0,986	1,036	1,218	1,288	1,511
Simulasi 5	1,013	0,973	0,955	0,843	1,036	0,912
Simulasi 6	0,982	1,024	0,998	1,394	1,105	1,438
Simulasi 7	1,002	0,907	0,953	0,486	1,192	0,947
Simulasi 8	0,984	0,878	1,022	0,812	1,045	0,803
Simulasi 9	0,917	0,930	0,899	1,073	0,940	1,098
Simulasi 10	1,019	0,967	0,939	0,812	0,874	1,402

Pemodelan Tahap Kedua Menggunakan GSTAR-FFNN

Pada pemodelan *hybrid* GSTAR-FFNN, *input* yang digunakan adalah variabel model GSTAR. Sehingga *input* terdiri dari 6 variabel. Berikut ini adalah arsitektur pemodelan *hybrid* GSTAR-FFNN.



Gambar 4.11 Arsitektur GSTAR-FFNN dengan 6 *Input* dan 1 *Hidden Layer*

dengan,

$$\mathbf{N}_{t-1}^{(1)*} = \begin{bmatrix} \mathbf{N}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-1}^{(2)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(3)} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-1}^{(2)} + w_{13}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{W}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-1}^{(1)} + w_{23}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-1}^{(1)} + w_{32}\mathbf{N}_{t-1}^{(2)} \end{bmatrix}, \quad \text{dan } \hat{\mathbf{N}}_t = \begin{bmatrix} \hat{\mathbf{N}}_t^{(1)} \\ \hat{\mathbf{N}}_t^{(2)} \\ \hat{\mathbf{N}}_t^{(3)} \end{bmatrix}.$$

Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* adalah 1, 2, 3, 4, 5, 10, dan 15. Fungsi aktivasi pada


hidden layer adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Tabel 4.8 menunjukkan hasil evaluasi model untuk data simulasi 1 menggunakan *hybrid* GSTARX-FFNN.

Tabel 4.8 Nilai Kebaikan Model *hybrid* GSTARX-FFNN Data Simulasi 1 Skenario I


Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,039	0,926	0,976	2,081	1,383	1,734
GSTARX-FFNN (6,2,1)	1,038	0,924	0,976	2,069	1,394	1,710
GSTARX-FFNN (6,3,1)	1,055	0,938	0,979	2,112	1,340	1,744
GSTARX-FFNN (6,4,1)	1,040	0,922	0,976	2,088	1,398	1,757
GSTARX-FFNN (6,5,1)	1,035	0,930	0,970	2,056	1,381	1,755
GSTARX-FFNN (6,10,1)	1,051	0,931	0,982	2,060	1,407	1,786
GSTARX-FFNN (6,15,1)*	1,154	1,060	1,120	1,956	1,282	1,770

Ket: *model terbaik

Berdasarkan Tabel 4.8, pemilihan model terbaik dilakukan berdasarkan kriteria data *testing*. Namun, berdasarkan data *testing*, terdapat perbedaan kesimpulan yang diperoleh untuk setiap lokasi. Dengan demikian, model terbaik yang dipilih merupakan model yang memiliki nilai minimum paling banyak di ketiga lokasi. Model *hybrid* GSTARX-FFNN dengan 6 *input*, 15 unit *neuron*, yang dapat dinotasikan *hybrid* GSTARX-FFNN(6,15,1) merupakan model dengan nilai RMSE terkecil. Selanjutnya adalah melakukan peramalan data simulasi 1 di ketiga lokasi menggunakan *hybrid* GSTARX-FFNN(6,15,1). Hasil ramalan di ketiga lokasi ditampilkan dalam bentuk plot *time series* pada Gambar 4.12.




Gambar 4.12 *Time Series Plot* Data Aktual dan Ramalan *Hybrid* GSTARX-FFNN Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3



Gambar 4.12 Time Series Plot Data Aktual dan Ramalan Hybrid GSTARX-FFNN Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3 (lanjutan)

Dapat dilihat bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender. Selanjutnya, untuk mengetahui pengaruh jumlah *neuron* terhadap nilai RMSE model *hybrid* GSTARX-FFNN dalam meramalkan data pada skenario I, dihitung nilai RMSE *in sample* dan *out sample* data simulasi dengan replikasi sebanyak 10 kali.



Gambar 4.13 Line Plot Pengaruh Jumlah Neuron Terhadap Nilai RMSE, *In Sample* (kiri) dan *Out Sample* (kanan), Model Hybrid GSTARX-FFNN

Berdasarkan Gambar 4.13 dapat diketahui bahwa pemodelan data simulasi dengan model *hybrid* GSTARX-FFNN untuk data *training* (*in sample*)

penambahan jumlah *neuron* cenderung mengurangi nilai RMSE. Rata-rata nilai RMSE terkecil diperoleh dengan menggunakan 10 unit *neuron*. Berdasarkan RMSE data *testing* (*out sample*), penambahan jumlah *neuron* tidak selalu meningkatkan akurasi. *Neuron* optimal yang menghasilkan rata-rata RMSE *training* terkecil adalah sebanyak 10 unit *neuron* dan *neuron* optimal yang menghasilkan rata-rata RMSE *testing* terkecil adalah 1 unit *neuron*. Rata-rata nilai RMSE data *training* cenderung lebih kecil jika dibandingkan dengan data *testing*.

Setelah diperoleh nilai tingkat kesalahan ramalan untuk masing-masing data simulasi (Lampiran 12-20), model *hybrid* GSTARX-FFNN terbaik untuk setiap data simulasi disajikan pada 4.9.

Tabel 4.9 Nilai Kebaikan Model *Hybrid* GSTARX-FFNN pada Skenario I


Data Simulasi	Model	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
1	GSTARX-FFNN (6,15,1)	1,154	1,060	1,120	1,956	1,282	1,770
2	GSTARX-FFNN (6,5,1)	0,931	0,948	1,001	1,380	1,318	1,134
3	GSTARX-FFNN (6,15,1)	1,053	1,032	1,020	1,114	0,839	0,931
4	GSTARX-FFNN (6,10,1)	1,051	1,021	1,087	1,129	1,308	1,401
5	GSTARX-FFNN (6,15,1)	1,012	0,962	0,953	0,840	1,066	0,906
6	GSTARX-FFNN (6,10,1)	1,111	1,071	1,118	1,279	1,039	1,212
7	GSTARX-FFNN (6,2,1)	1,053	0,941	0,960	0,358	1,115	0,974
8	GSTARX-FFNN (6,10,1)	1,091	0,902	1,073	0,785	1,074	0,698
9	GSTARX-FFNN (6,3,1)	1,273	1,291	1,146	0,947	0,804	1,070
10	GSTARX-FFNN (6,15,1)	0,996	0,980	0,917	0,735	0,809	1,413

Tabel 4.9 memperlihatkan model terbaik untuk setiap data simulasi dengan menggunakan *hybrid* GSTARX-FFNN. Dari 10 kali replikasi, model *hybrid* GSTARX-FFNN menghasilkan model terbaik dengan jumlah *neuron* yang bervariasi. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* untuk mendapatkan model yang optimum.

Pemodelan Tahap Kedua Menggunakan GSTAR-DLNN

Pada pemodelan *hybrid* GSTAR-DLNN, *input* yang digunakan adalah variabel pada model GSTAR yang terdiri dari 6 variabel. Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* pada *hidden layer* pertama adalah 1, 2, 3, 4, 5, 10, dan 15, sedangkan *hidden layer* kedua jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, 5. Fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output*

layer adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Berikut ini adalah arsitektur pemodelan *hybrid* GSTAR-DLNN.



Gambar 4.14 Arsitektur GSTAR-ANN dengan 6 *Input* dan 2 *Hidden Layer*

dengan,

$$\mathbf{N}_{t-1}^{(1)*} = \begin{bmatrix} \mathbf{N}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-1}^{(2)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(3)} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-1}^{(2)} + w_{13}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{W}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-1}^{(1)} + w_{23}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-1}^{(1)} + w_{32}\mathbf{N}_{t-1}^{(2)} \end{bmatrix}, \quad \text{dan } \hat{\mathbf{N}}_t = \begin{bmatrix} \hat{\mathbf{N}}_t^{(1)} \\ \hat{\mathbf{N}}_t^{(2)} \\ \hat{\mathbf{N}}_t^{(3)} \end{bmatrix}.$$

Tabel 4.10 menunjukkan hasil evaluasi model untuk data simulasi 1 dengan *hybrid* GSTARX-DLNN.

Tabel 4.10 Nilai Keباikan Model *hybrid* GSTARX-DLNN Data Simulasi 1 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,034	0,923	0,974	2,087	1,388	1,729
GSTARX-DLNN (6,1,2,1)	1,040	0,925	0,975	2,096	1,389	1,737
GSTARX-DLNN (6,1,3,1)	1,039	0,924	0,975	2,077	1,387	1,729
GSTARX-DLNN (6,1,4,1)	1,038	0,925	0,975	2,085	1,387	1,734
GSTARX-DLNN (6,1,5,1)	1,036	0,924	0,974	2,081	1,387	1,726
GSTARX-DLNN (6,2,1,1)	1,060	0,937	0,978	2,107	1,398	1,857
GSTARX-DLNN (6,2,2,1)	1,069	0,934	0,983	2,144	1,409	1,811
GSTARX-DLNN (6,2,3,1)	1,030	0,920	0,973	2,055	1,388	1,708
GSTARX-DLNN (6,2,4,1)	1,031	0,922	0,975	2,064	1,381	1,733
GSTARX-DLNN (6,2,5,1)	1,042	0,928	0,975	2,091	1,393	1,754


Tabel 4.10 Nilai Kebaikan Model *hybrid* GSTARX-DLNN Data Simulasi 1 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,3,1,1)*	1,041	0,912	0,975	2,091	1,459	1,733
GSTARX-DLNN (6,3,2,1)	1,032	0,918	0,969	2,127	1,423	1,728
GSTARX-DLNN (6,3,3,1)	1,024	0,913	0,966	2,072	1,393	1,614
GSTARX-DLNN (6,3,4,1)	1,098	0,975	0,998	2,077	1,435	1,820
GSTARX-DLNN (6,3,5,1)	1,115	0,963	1,010	2,041	1,350	1,815
GSTARX-DLNN (6,4,1,1)	1,054	0,929	0,977	2,137	1,395	1,795
GSTARX-DLNN (6,4,2,1)	1,228	1,144	1,145	2,058	1,248	1,815
GSTARX-DLNN (6,4,3,1)	1,034	0,920	0,970	2,076	1,416	1,757
GSTARX-DLNN (6,4,4,1)	1,055	0,929	0,978	2,118	1,418	1,777
GSTARX-DLNN (6,4,5,1)	1,029	0,918	0,967	2,015	1,421	1,722
GSTARX-DLNN (6,5,1,1)	1,030	0,919	0,968	2,038	1,405	1,754
GSTARX-DLNN (6,5,2,1)	1,126	0,969	1,019	2,083	1,401	1,872
GSTARX-DLNN (6,5,3,1)	1,027	0,916	0,960	2,083	1,482	1,702
GSTARX-DLNN (6,5,4,1)	1,025	0,917	0,965	2,046	1,459	1,701
GSTARX-DLNN (6,5,5,1)	1,257	1,060	1,055	2,061	1,397	1,878
GSTARX-DLNN (6,10,1,1)	1,069	0,937	0,984	2,108	1,398	1,797
GSTARX-DLNN (6,10,2,1)	1,020	0,903	0,952	1,972	1,434	1,811
GSTARX-DLNN (6,10,3,1)	1,014	0,897	0,947	2,072	1,462	1,697
GSTARX-DLNN (6,10,4,1)	1,091	0,994	1,006	2,083	1,382	1,778
GSTARX-DLNN (6,10,5,1)	1,047	0,930	0,980	2,085	1,428	1,810
GSTARX-DLNN (6,15,1,1)	1,029	0,902	0,964	2,058	1,517	1,773
GSTARX-DLNN (6,15,2,1)	1,013	0,889	0,941	1,983	1,519	1,764
GSTARX-DLNN (6,15,3,1)	1,028	0,908	0,967	2,092	1,468	1,704
GSTARX-DLNN (6,15,4,1)	1,022	0,897	0,952	2,034	1,452	1,671
GSTARX-DLNN (6,15,5,1)	1,024	0,904	0,963	2,060	1,451	1,706

Ket: *model terbaik


Berdasarkan Tabel 4.6, pemilihan model terbaik dilakukan berdasarkan kriteria data *testing*. Namun, berdasarkan data *testing*, terdapat perbedaan kesimpulan yang diperoleh untuk setiap lokasi. Dengan demikian, model terbaik yang dipilih merupakan model yang memiliki rata-rata RMSE terkecil di ketiga lokasi. Model *hybrid* GSTARX-DLNN dengan 6 *input*, 3 unit *neuron* pada *hidden layer* pertama, dan 3 unit *neuron* pada *hidden layer* kedua, yang dapat dinotasikan *hybrid* GSTARX-DLNN(6,3,3,1) merupakan model dengan rata-rata RMSE terkecil di ketiga lokasi. Gambar 4.15 merupakan *time series plot* hasil ramalan *in sample* dan *out sample* data simulasi 1 menggunakan model *hybrid* GSTARX-

DLNN(6,3,3,1) di tiga lokasi. Dapat dilihat bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender.




Gambar 4.15 Time Series Plot Data Aktual dan Ramalan Hybrid GSTARX-DLNN Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3

Selanjutnya, untuk mengetahui pengaruh jumlah *neuron* dan *hidden layer* terhadap nilai RMSE model *hybrid* GSTARX-DLNN dalam meramalkan data pada skenario I, dihitung nilai RMSE *in sample* dan *out sample* data simulasi dengan replikasi sebanyak 10 kali.



Gambar 4.16 Line Plot Pengaruh Jumlah Neuron Terhadap Nilai RMSE, *In Sample* (kiri) dan *Out Sample* (kanan), Model Hybrid GSTARX-DLNN

Pada Gambar 4.16 terlihat bahwa pemodelan data simulasi dengan model *hybrid* GSTARX-DLNN, untuk data *training* penambahan jumlah *neuron* pada *hidden layer* pertama tidak selalu meningkatkan akurasi ramalan dan masih tergantung pada jumlah *neuron* pada *hidden layer* kedua. Sama halnya dengan data *training*, penambahan jumlah *neuron* pada *hidden layer* pertama data *testing* tidak selalu meningkatkan akurasi ramalan dan masih tergantung pada jumlah *neuron* pada *hidden layer* kedua. Pengaruh jumlah *neuron* terhadap perubahan akurasi ramalan pada data *testing* relatif lebih kecil dibandingkan dengan perubahan akurasi ramalan pada data *training*.



Gambar 4.17 Line Plot Pengaruh Jumlah Hidden Layer Terhadap Nilai RMSE, *In Sample* (kiri) dan *Out Sample* (kanan) Model Hybrid GSTARX-ANN

Dengan hanya memperhatikan jumlah *neuron* pada *hidden layer* pertama model DLNN, dibandingkan rata-rata nilai RMSE model FFNN dengan DLNN. Untuk data *training* terlihat bahwa model FFNN memberikan rata-rata nilai RMSE lebih kecil pada semua jumlah unit *neuron* dibandingkan model DLNN. Sedangkan untuk data *testing*, model DLNN menghasilkan rata-rata nilai RMSE yang lebih kecil dibandingkan model FFNN. Dalam menentukan jumlah *neuron*

dan *hidden layer* optimal diperlukan *trial and error* pada model *neural network* karena penambahan jumlah *neuron* dan *hidden layer* tidak selalu meningkatkan akurasi ramalan.

Setelah diperoleh nilai tingkat kesalahan ramalan untuk masing-masing data simulasi (Lampiran 12-20), maka model *hybrid* GSTARX-DLNN terbaik untuk setiap data simulasi disajikan pada 4.11.


Tabel 4.11 Nilai Kebaikan Model *Hybrid* GSTARX-DLNN pada Skenario I

Data Simulasi	Model	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
1	GSTARX-DLNN (6,3,1,1)	1,041	0,912	0,975	2,091	1,459	1,733
2	GSTARX-DLNN (6,3,2,1)	0,925	0,921	0,986	1,380	1,329	1,164
3	GSTARX-DLNN (6,15,4,1)	1,036	1,021	0,960	1,149	0,795	0,991
4	GSTARX-DLNN (6,15,3,1)	0,919	0,980	1,000	1,268	1,199	1,406
5	GSTARX-DLNN (6,4,4,1)	1,419	1,125	1,065	0,758	0,960	0,948
6	GSTARX-DLNN (6,1,1,1)	1,021	1,030	1,025	1,332	1,074	1,282
7	GSTARX-DLNN (6,4,2,1)	1,046	0,929	0,980	0,382	1,085	0,836
8	GSTARX-DLNN (6,3,5,1)	1,178	1,030	1,136	0,804	0,978	0,708
9	GSTARX-DLNN (6,10,4,1)	1,126	0,980	1,007	0,940	0,802	1,035
10	GSTARX-DLNN (6,3,5,1)	0,992	0,979	0,919	0,748	0,850	1,420

Tabel 4.11 memperlihatkan model terbaik untuk setiap data simulasi dengan menggunakan *hybrid* GSTARX-DLNN. Dari 10 kali replikasi, masing-masing model terbaik memiliki jumlah *neuron* yang bervariasi. Hal ini semakin menguatkan konsep *trial and error* dalam menentukan jumlah *neuron* dan *hidden layer* untuk mendapatkan model yang optimum.


c. Perbandingan Model VARX, GSTARX, dan *Hybrid* GSTARX-ANN pada Skenario I

Data simulasi pada skenario I merupakan data *space time* yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* linier yang dibangkitkan mengikuti model GSTAR(1₁). Setelah dilakukan pemodelan dengan menggunakan model VARX, GSTARX, *hybrid* GSTARX-FFNN, dan *hybrid* GSTARX-DLNN dilakukan perbandingan akurasi ramalan, model terbaik dipilih berdasarkan kriteria RMSE terkecil pada data *out sample*.




Gambar 4.18 Line Plot Nilai RMSE Skenario I di Tiga Lokasi, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3

Berdasarkan Gambar 4.18, terlihat nilai RMSE model *Hybrid* GSTARX-ANN yang terdiri dari model *hybrid* GSTARX-FFNN dan *hybrid* GSTARX-DLNN memiliki nilai RMSE *out sample* yang relatif lebih kecil pada masing-masing data simulasi di ketiga lokasi dibandingkan dengan metode VARX maupun GSTARX. Berikut disajikan *box plot* nilai RMSE data *out sample*.



Gambar 4.19 Box Plot Nilai RMSE di Tiga Lokasi pada Skenario I

Berdasarkan Gambar 4.19, terlihat bahwa pemodelan skenario I dengan menggunakan *hybrid* GSTARX-FFNN maupun *hybrid* GSTARX-DLNN memberikan hasil ramalan yang lebih akurat dibandingkan GSTARX dan VARX. Hal ini terlihat dari nilai tengah dan *mean* dari RMSE model *hybrid* yang lebih kecil dibandingkan model GSTARX maupun VARX di ketiga lokasi. Setelah diperoleh model terbaik untuk setiap metode, dilakukan perbandingan untuk mengetahui metode terbaik dalam meramalkan data simulasi skenario I. Model terbaik setiap data simulasi skenario I ditunjukkan oleh Gambar 4.20.



Gambar 4.20 Model Terbaik Data Simulasi Skenario I

Gambar 4.20 menunjukkan bahwa pada lokasi 1, model GSTARX-FFNN merupakan model terbaik sebanyak 7 replikasi dan GSTARX-DLNN sebanyak 3 replikasi. Pada lokasi 2, model GSTARX-FFNN merupakan model terbaik sebanyak 3 replikasi dan GSTARX-DLNN sebanyak 6 replikasi. Di lokasi 3, model GSTARX-FFNN merupakan model terbaik sebanyak 5 replikasi. Secara keseluruhan model *hybrid* GSTARX-ANN merupakan model terbaik dalam meramalkan data yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* linier dibandingkan model GSTARX dan VARX.

4.1.2 Pemodelan Data Simulasi Skenario II


Pada skenario II, deret *noise* merupakan deret yang belum *white noise* dan berpola nonlinier, bangkitan data pada skenario II dapat dilihat pada persamaan berikut

$$\begin{aligned} N_{1,t} &= 4N_{1,t-1} \times \exp(-0,25N_{1,t-1}^2) + 1,25N_{2,t-1} \times \exp(-0,25N_{2,t-1}^2) + 1,5N_{3,t-1} \times \\ &\quad \exp(-0,25N_{3,t-1}^2) + a_{1,t}, \\ N_{2,t} &= 1,25N_{1,t-1} \times \exp(-0,25N_{1,t-1}^2) + 3,5N_{2,t-1} \times \exp(-0,25N_{2,t-1}^2) + 1,6N_{3,t-1} \times \\ &\quad \exp(-0,25N_{3,t-1}^2) + a_{2,t}, \\ N_{3,t} &= 1,6N_{1,t-1} \times \exp(-0,25N_{1,t-1}^2) + 1,1N_{2,t-1} \times \exp(-0,25N_{2,t-1}^2) + 3N_{3,t-1} \times \\ &\quad \exp(-0,25N_{3,t-1}^2) + a_{3,t}. \end{aligned}$$

Residual data bangkitan antar lokasi saling berkorelasi, dengan matriks varians kovarians yaitu Σ dan *mean* $\mathbf{0}$. Matriks varians kovarians residual pada skenario II sebagai berikut

$$\Sigma = \begin{bmatrix} 1,00 & 0,65 & 0,60 \\ 0,65 & 1,00 & 0,55 \\ 0,60 & 0,55 & 1,00 \end{bmatrix}.$$

Selanjutnya, ditampilkan identifikasi deret *noise* melalui matriks plot antara *noise* pada waktu ke- t dengan *noise* pada waktu ke $t-1$ di tiga lokasi yang ditunjukkan pada Gambar 4.21.



Gambar 4.21 Matriks Plot Deret *Noise* Nonlinier di Tiga Lokasi

Pada Gambar 4.21 terlihat matriks plot yang terbentuk antara deret *noise* pada waktu ke- t dengan deret *noise* pada waktu ke $t-1$ masing-masing lokasi berpola nonlinier. Setelah didapatkan data bangkitan $Z_t^{(i)}$ sesuai dengan persamaan (3.6) dengan replikasi sebanyak 10 kali, kemudian dilakukan pemodelan secara dua tahap. Berikut adalah pembahasan pemodelan simulasi skenario II.

a. Pemodelan Tahap Pertama Data Simulasi Skenario II

Tahap pertama dilakukan pemodelan pola tren, musiman, dan variasi kalender menggunakan *time series regression* dengan metode estimasi yaitu GLS. Hasil estimasi parameter tahap pertama data simulasi 1 skenario II disajikan pada Tabel 4.12.

Tabel 4.12 Estimasi Parameter Tahap I pada Data Simulasi 1 Skenario II

Lokasi	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
1	t	1	0,206	0,004	48,65	<0,0001
	S ₁	1	21,969	0,834	26,34	<0,0001
	S ₂	1	24,843	0,836	29,72	<0,0001
	S ₃	1	26,496	0,838	31,63	<0,0001
	S ₄	1	24,877	0,840	29,63	<0,0001
	S ₅	1	20,677	0,841	24,57	<0,0001
	S ₆	1	15,013	0,853	17,60	<0,0001
	S ₇	1	11,324	0,875	12,94	<0,0001

Tabel 4.12 Estimasi Parameter Tahap I pada Data Simulasi 1 Skenario II (lanjutan)

Lokasi	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
1	S ₈	1	8,250	0,878	9,40	<0,0001
	S ₉	1	4,768	0,888	5,37	<0,0001
	S ₁₀	1	9,279	0,908	10,22	<0,0001
	S ₁₁	1	13,161	0,900	14,63	<0,0001
	S ₁₂	1	17,452	0,872	20,00	<0,0001
	V _{1,t}	1	29,315	1,757	16,68	<0,0001
	V _{2,t}	1	41,678	1,523	27,37	<0,0001
	V _{3,t}	1	50,069	1,518	32,98	<0,0001
	V _{4,t}	1	50,749	1,522	33,34	<0,0001
	V _{1,t-1}	1	49,977	1,762	28,36	<0,0001
	V _{2,t-1}	1	47,209	1,523	31,00	<0,0001
	V _{3,t-1}	1	42,389	1,518	27,92	<0,0001
	V _{4,t-1}	1	34,360	1,518	22,63	<0,0001
2	t	1	0,229	0,004	55,96	<0,0001
	S ₁	1	25,227	0,804	31,36	<0,0001
	S ₂	1	28,828	0,806	35,76	<0,0001
	S ₃	1	29,454	0,808	36,46	<0,0001
	S ₄	1	28,386	0,810	35,06	<0,0001
	S ₅	1	24,006	0,812	29,58	<0,0001
	S ₆	1	19,104	0,823	23,22	<0,0001
	S ₇	1	14,616	0,844	17,32	<0,0001
	S ₈	1	11,954	0,846	14,13	<0,0001
	S ₉	1	8,097	0,857	9,45	<0,0001
	S ₁₀	1	13,157	0,875	15,03	<0,0001
	S ₁₁	1	15,912	0,868	18,33	<0,0001
	S ₁₂	1	21,511	0,841	25,57	<0,0001
	V _{1,t}	1	43,694	1,695	25,78	<0,0001
	V _{2,t}	1	46,728	1,469	31,82	<0,0001
	V _{3,t}	1	56,439	1,464	38,55	<0,0001
	V _{4,t}	1	58,898	1,468	40,12	<0,0001
	V _{1,t-1}	1	59,326	1,700	34,91	<0,0001
	V _{2,t-1}	1	53,769	1,468	36,62	<0,0001
	V _{3,t-1}	1	47,187	1,464	32,23	<0,0001
	V _{4,t-1}	1	36,493	1,464	24,92	<0,0001
3	t	1	0,236	0,004	61,81	<0,0001
	S ₁	1	17,261	0,752	22,96	<0,0001
	S ₂	1	22,064	0,754	29,28	<0,0001
	S ₃	1	23,842	0,755	31,57	<0,0001
	S ₄	1	21,636	0,757	28,59	<0,0001
	S ₅	1	16,206	0,759	21,36	<0,0001

Tabel 4.12 Estimasi Parameter Tahap I pada Data Simulasi 1 Skenario II (lanjutan)

Lokasi	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
	S ₆	1	10,439	0,769	13,57	<0,0001
	S ₇	1	8,052	0,789	10,21	<0,0001
	S ₈	1	5,027	0,791	6,35	<0,0001
	S ₉	1	3,040	0,801	3,80	0,0002
	S ₁₀	1	5,798	0,818	7,09	<0,0001
	S ₁₁	1	9,493	0,811	11,70	<0,0001
	S ₁₂	1	12,357	0,786	15,71	<0,0001
	V _{1,t}	1	35,740	1,584	22,56	<0,0001
	V _{2,t}	1	38,653	1,373	28,16	<0,0001
	V _{3,t}	1	49,138	1,369	35,90	<0,0001
	V _{4,t}	1	51,725	1,372	37,69	<0,0001
	V _{1,t-1}	1	49,235	1,589	30,99	<0,0001
	V _{2,t-1}	1	47,231	1,373	34,41	<0,0001
	V _{3,t-1}	1	44,456	1,369	32,48	<0,0001
	V _{4,t-1}	1	36,925	1,369	26,98	<0,0001

Pada Tabel 4.12 semua parameter yang diestimasi pada tahap pertama sudah signifikan sehingga didapatkan model persamaan sebagai berikut

$$\begin{aligned}
Z_t^{(1)} = & 0,205t + 21,969S_{1,t} + 24,843S_{2,t} + 26,496S_{3,t} + 24,877S_{4,t} + 20,677S_{5,t} + \\
& 15,013S_{6,t} + 11,324S_{7,t} + 8,25S_{8,t} + 4,768S_{9,t} + 9,279S_{10,t} + 13,161S_{11,t} + \\
& 17,452S_{12,t} + 29,315V_{1,t} + 41,678V_{2,t} + 50,069V_{3,t} + 50,749V_{4,t} + \\
& 49,977V_{1,t-1} + 47,209V_{2,t-1} + 42,389V_{3,t-1} + 34,36V_{4,t-1} + N_{1,t}.
\end{aligned} \tag{4.4}$$


$$\begin{aligned}
Z_t^{(2)} = & 0,229t + 25,227S_{1,t} + 28,828S_{2,t} + 29,454S_{3,t} + 28,386S_{4,t} + 24,006S_{5,t} + \\
& 19,104S_{6,t} + 14,616S_{7,t} + 11,954S_{8,t} + 8,097S_{9,t} + 13,157S_{10,t} + 15,912S_{11,t} + \\
& 21,511S_{12,t} + 43,694V_{1,t} + 46,728V_{2,t} + 56,439V_{3,t} + 58,898V_{4,t} + 59,326V_{1,t-1} + \\
& 53,769V_{2,t-1} + 47,187V_{3,t-1} + 36,493V_{4,t-1} + N_{2,t}.
\end{aligned} \tag{4.5}$$

$$\begin{aligned}
Z_t^{(3)} = & 0,236t + 17,261S_{1,t} + 22,064S_{2,t} + 23,842S_{3,t} + 21,636S_{4,t} + 16,206S_{5,t} + \\
& 10,439S_{6,t} + 8,052S_{7,t} + 5,027S_{8,t} + 3,04S_{9,t} + 5,798S_{10,t} + 9,493S_{11,t} + \\
& 12,357S_{12,t} + 35,74V_{1,t} + 38,653V_{2,t} + 49,138V_{3,t} + 51,725V_{4,t} + \\
& 49,235V_{1,t-1} + 47,231V_{2,t-1} + 44,456V_{3,t-1} + 36,925V_{4,t-1} + N_{3,t}.
\end{aligned} \tag{4.6}$$

Persamaan (4.4)–(4.6) dapat disajikan dalam bentuk matriks sebagai berikut

$$\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,205 & 0 & 0 \\ 0 & 0,229 & 0 \\ 0 & 0 & 0,236 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \end{bmatrix} + \begin{bmatrix} 21,969 & 0 & 0 \\ 0 & 25,227 & 0 \\ 0 & 0 & 17,261 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 42,39 & 0 & 0 \\ 0 & 47,19 & 0 \\ 0 & 0 & 44,46 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 34,36 & 0 & 0 \\ 0 & 36,493 & 0 \\ 0 & 0 & 36,925 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix}.$$

Setelah dilakukan pemodelan tahap pertama, didapatkan nilai residual yang disajikan pada matriks *plot* sebagai berikut



Gambar 4.22 Matriks Plot Residual Tahap Pertama Data Simulasi 1 Skenario II


Berdasarkan matrik plot pada Gambar 4.22, residual tahap pertama mengandung pola nonlinier. Nilai residual pada tahap pertama selanjutnya dimodelkan menggunakan VAR, GSTAR, dan *hybrid* GSTAR-ANN.

b. Pemodelan Tahap Kedua Data Simulasi Skenario II

Tahap kedua dilakukan pemodelan residual tahap pertama menggunakan metode VAR, GSTAR, *hybrid* GSTAR-FFNN, dan *hybrid* GSTAR-DLNN. Berikut adalah pembahasan masing-masing metode pada pemodelan tahap kedua data simulasi skenario II.

Pemodelan Tahap Kedua Menggunakan VAR

Pertama dilakukan identifikasi data simulasi di ketiga lokasi untuk mengetahui apakah data yang digunakan sudah stasioner. Proses identifikasi stasioneritas secara visual dengan melihat *time series plot* yang ditampilkan pada Gambar 4.23.



Gambar 4.23 Plot *Time Series* Residual Tahap Pertama

Gambar 4.23 memperlihatkan residual dari ketiga lokasi berada disekitar $\mu = 0$. Selain itu, identifikasi stasioneritas juga dapat dilihat berdasarkan skematik MCCF pada Gambar 4.24.

Schematic Representation of Cross Correlations													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	+++	+++	+++	..+	+..-
zresid2	+++	+++	+++	+++	+..	+..	+..-
zresid3	+++	+++	+++	..+	+++	+..	+..	...	---

Gambar 4.24 Representasi Skematik MCCF Residual Data Simulasi 1

Gambar 4.24 menunjukkan bahwa data sudah stasioner terlihat dari skema MCCF yang cenderung turun cepat (*dies down*). Sedangkan skema MPCCF signifikan pada lag 2. Berdasarkan plot MPCCF tersebut, dapat diketahui bahwa orde dari model yang diduga adalah VAR(2).

Schematic Representation of Partial Cross Correlations												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	++	++	...	-..
zresid2	+++	..+
zresid3	..+	...	-..	-..

Gambar 4.25 Representasi Skematik MPCCF Residual Data Simulasi 1

Selain melakukan pengecekan melalui plot MCCF dan MPCCF, perlu dilakukan pengecekan terhadap nilai AIC dari model.

Tabel 4.13 Nilai AIC Model VAR Residual Skenario II Simulasi 1

Lag	MA 0	MA 1	MA 2	MA 3
AR 0	2,320	2,287	2,122	2,100
AR 1	2,010	2,133	2,088	2,139
AR 2	1,996	2,085	2,182	2,229
AR 3	2,061	2,134	2,213	2,322
AR 4	2,075	2,178	2,251	2,325
AR 5	2,146	2,237	2,326	2,351
AR 6	2,255	2,386	2,482	2,515
AR 7	2,329	2,467	2,610	2,645
AR 8	2,370	2,514	2,665	2,822
AR 9	2,505	2,656	2,814	2,980

Pada Tabel 4.13 menunjukkan bahwa nilai AIC terkecil dari model VAR adalah terletak di lag MA 0 dan AR 2. Hal ini sama seperti yang diduga oleh plot MPCCF yaitu VAR(2).

Hasil estimasi parameter model VAR(2) memiliki 18 parameter. Akan tetapi, jika dilihat dari nilai *p-value* masing-masing parameter dapat diketahui bahwa tidak semua parameter memiliki pengaruh yang signifikan terhadap model. Pada simulasi ini model yang digunakan adalah semua parameter, untuk meningkatkan akurasi model seperti yang sudah dilakukan sebelumnya pada skenario I, bahwa dengan melibatkan semua parameter memberikan kesalahan ramalan yang lebih kecil dibandingkan *restricted model*. Hasil estimasi parameter dari model VAR(2) pada Tabel 4.14.

Tabel 4.14 Estimasi Parameter VAR(2)

Lokasi	Parameter	Estimasi	Standar Error	t-value	P-value	Variabel
1	ϕ_{11}^1	0,145	0,163	0,89	0,3770	$N_{t-1}^{(1)}$
	ϕ_{12}^1	0,389	0,169	2,31	0,0222	$N_{t-1}^{(2)}$
	ϕ_{13}^1	-0,195	0,214	-0,91	0,3617	$N_{t-1}^{(3)}$
	ϕ_{11}^2	0,173	0,165	1,05	0,2958	$N_{t-2}^{(1)}$
	ϕ_{12}^2	0,040	0,171	0,23	0,8151	$N_{t-2}^{(2)}$
	ϕ_{13}^2	0,031	0,214	0,15	0,8845	$N_{t-2}^{(3)}$
2	ϕ_{21}^1	-0,021	0,153	-0,14	0,8921	$N_{t-1}^{(1)}$
	ϕ_{22}^1	0,459	0,158	2,91	0,0040	$N_{t-1}^{(2)}$
	ϕ_{23}^1	-0,083	0,200	-0,42	0,6782	$N_{t-1}^{(3)}$
	ϕ_{21}^2	0,054	0,154	0,35	0,7249	$N_{t-2}^{(1)}$
	ϕ_{22}^2	0,289	0,160	1,81	0,0721	$N_{t-2}^{(2)}$
	ϕ_{23}^2	-0,118	0,200	-0,59	0,5552	$N_{t-2}^{(3)}$

Tabel 4.14 Estimasi Parameter VAR(2) (lanjutan)

Lokasi	Parameter	Estimasi	Standar Error	t-value	P-value	Variabel
3	ϕ_{31}^1	-0,117	0,146	-0,80	0,4226	$N_{t-1}^{(1)}$
	ϕ_{32}^1	0,322	0,150	2,14	0,0335	$N_{t-1}^{(2)}$
	ϕ_{33}^1	0,145	0,191	0,76	0,4496	$N_{t-1}^{(3)}$
	ϕ_{31}^2	0,018	0,147	0,12	0,9018	$N_{t-2}^{(1)}$
	ϕ_{32}^2	0,099	0,152	0,65	0,5142	$N_{t-2}^{(2)}$
	ϕ_{33}^2	0,088	0,191	0,46	0,6467	$N_{t-2}^{(3)}$

Berdasarkan *full model* maka dapat dibentuk persamaan matematis model VARX(2) dalam bentuk matriks seperti berikut

Persamaan tahap I

$$\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,205 & 0 & 0 \\ 0 & 0,229 & 0 \\ 0 & 0 & 0,236 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \end{bmatrix} + \begin{bmatrix} 21,969 & 0 & 0 \\ 0 & 25,227 & 0 \\ 0 & 0 & 17,261 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 42,39 & 0 & 0 \\ 0 & 47,19 & 0 \\ 0 & 0 & 44,46 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 34,36 & 0 & 0 \\ 0 & 36,493 & 0 \\ 0 & 0 & 36,925 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix}.$$

Persamaan tahap II


$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,145 & 0,389 & -0,195 \\ -0,021 & 0,459 & -0,083 \\ -0,117 & 0,322 & 0,145 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,173 & 0,040 & 0,031 \\ 0,054 & 0,289 & -0,118 \\ 0,018 & 0,099 & 0,088 \end{bmatrix} \begin{bmatrix} N_{t-2}^{(1)} \\ N_{t-2}^{(2)} \\ N_{t-2}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}.$$

Selanjutnya, untuk mengetahui kebaikan model VARX dalam meramalkan data simulasi pada skenario II, dihitung nilai RMSE *in sample* maupun *out sample* yang disajikan pada Tabel 4.15.

Tabel 4.15 Nilai Kebaikan Model VARX pada Skenario II

Data	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
Simulasi 1	2,383	2,228	2,126	4,623	3,985	3,884
Simulasi 2	2,260	2,196	1,933	2,787	2,901	2,103
Simulasi 3	2,569	2,365	2,248	2,644	2,312	2,239
Simulasi 4	2,234	2,165	1,999	3,626	2,766	3,400
Simulasi 5	2,334	2,163	1,844	2,260	2,449	1,818
Simulasi 6	2,364	2,110	2,055	1,926	1,387	1,790
Simulasi 7	2,498	2,370	2,205	3,798	3,648	2,813
Simulasi 8	2,254	2,049	1,942	3,715	3,594	3,455
Simulasi 9	2,412	2,338	2,158	2,491	2,520	2,428
Simulasi 10	2,246	2,123	1,997	3,021	2,362	2,439

Setelah didapatkan nilai kebaikan model, untuk mengetahui apakah model VARX dapat menangkap pola data yang mengandung tren, musiman, dan variasi kalender, berikut disajikan *time series plot* hasil ramalan di tiga lokasi untuk data simulasi 1.



Gambar 4.26 *Time Series Plot* Data Ramalan Model VARX(2) Data Simulasi 1, (a) Lokasi 1, (b) Lokasi 2, (c) Lokasi 3

Berdasarkan Gambar 4.26, *time series plot* ramalan *in sample* maupun *out sample* data simulasi 1 di tiga lokasi, sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender meskipun masih ada jarak yang relatif besar antara data ramalan dan data aktual di beberapa titik ramalan *out sample*.

Pemodelan Tahap Kedua Menggunakan GSTAR

Orde model yang digunakan dalam pemodelan GSTAR adalah sama dengan orde VAR pada pemodelan sebelumnya, yaitu GSTAR(2₁). Pada pemodelan GSTAR menggunakan *full model* yang melibatkan semua parameter model tanpa memperhatikan signifikansinya, sehingga relevan dibandingkan dengan *full model* VAR. Bobot lokasi yang digunakan adalah bobot seragam yang mengasumsikan bahwa setiap lokasi bersifat homogen dengan estimasi parameter yaitu GLS. Hasil estimasi parameter model GSTAR(2₁) data simulasi 1 disajikan pada Tabel 4.16.


Tabel 4.16 Koefisien Parameter Tahap Dua Model GSTAR(2₁) Simulasi 1

Lokasi	Parameter	Estimasi	Standar Error	t-value	P-value
1	ϕ_{10}^1	0,252	0,081	3,13	0,0021
	ϕ_{11}^1	0,092	0,099	0,93	0,3549
	ϕ_{10}^2	0,193	0,081	2,37	0,0188
	ϕ_{11}^2	0,061	0,100	0,61	0,5427
2	ϕ_{20}^1	0,175	0,080	2,19	0,0300
	ϕ_{21}^1	0,186	0,090	2,06	0,0413
	ϕ_{20}^2	0,228	0,081	2,80	0,0056
	ϕ_{21}^2	0,013	0,090	0,15	0,8839
3	ϕ_{30}^1	0,336	0,086	3,92	0,0001
	ϕ_{31}^1	0,021	0,091	0,23	0,8194
	ϕ_{30}^2	0,143	0,086	1,66	0,0978
	ϕ_{31}^2	0,073	0,092	0,79	0,4293

Hasil estimasi parameter model GSTAR(2₁) data simulasi 1 untuk tahap kedua dapat dituliskan sebagai berikut

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,252 & 0 & 0 \\ 0 & 0,175 & 0 \\ 0 & 0 & 0,336 \end{bmatrix} + \begin{bmatrix} 0,092 & 0 & 0 \\ 0 & 0,186 & 0 \\ 0 & 0 & 0,021 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \\
 \begin{bmatrix} 0,193 & 0 & 0 \\ 0 & 0,228 & 0 \\ 0 & 0 & 0,143 \end{bmatrix} + \begin{bmatrix} 0,061 & 0 & 0 \\ 0 & 0,013 & 0 \\ 0 & 0 & 0,073 \end{bmatrix} \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix} \begin{bmatrix} N_{t-2}^{(1)} \\ N_{t-2}^{(2)} \\ N_{t-2}^{(3)} \end{bmatrix} + \\
 \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}$$

Kemudian dilakukan peramalan data simulasi 1 di ketiga lokasi menggunakan GSTARX(2₁). Hasil ramalan di ketiga lokasi ditampilkan dalam bentuk plot *time series*, seperti ditunjukkan pada Gambar 4.27.



Gambar 4.27 Time Series Plot Data Aktual dan Ramalan GSTARX(2₁) Data Simulasi 1


Time series plot ramalan *in sample* maupun *out sample* data simulasi 1 di tiga lokasi terlihat sudah mengikuti pola data simulasi meskipun di beberapa titik masih ada jarak yang relatif kecil antara ramalan dan data aktual. Selanjutnya, untuk mengetahui kebaikan model GSTARX dalam meramalkan data simulasi pada skenario II, dihitung nilai RMSE *in sample* maupun *out sample* yang disajikan pada Tabel 4.17.

Tabel 4.17 Nilai Kebaikan Model GSTARX pada Skenario II

Data	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
Simulasi 1	2,414	2,255	2,158	3,545	3,072	3,091
Simulasi 2	2,310	2,251	1,989	2,256	2,277	1,748
Simulasi 3	2,595	2,414	2,263	2,928	2,347	2,171
Simulasi 4	2,250	2,174	2,012	3,359	2,696	2,895
Simulasi 5	2,347	2,173	1,858	2,376	2,427	1,549
Simulasi 6	2,391	2,126	2,074	2,145	1,563	2,113
Simulasi 7	2,592	2,454	2,268	2,591	2,647	1,866
Simulasi 8	2,272	2,052	1,955	3,100	2,933	3,183
Simulasi 9	2,463	2,404	2,202	2,202	2,472	2,531
Simulasi 10	2,261	2,128	2,006	2,159	1,649	2,228

Pemodelan Tahap Kedua Menggunakan GSTAR-FFNN

Input yang digunakan pada pemodelan *hybrid* GSTAR-FFNN skenario II adalah semua variabel GSTAR yaitu terdiri dari 12 variabel dengan arsitektur sebagai berikut



Gambar 4.28 Arsitektur GSTAR-FFNN dengan 12 *Input* dan 1 *Hidden Layer*

dengan,

$$\begin{aligned}
 \mathbf{N}_{t-1}^{(1)*} &= \begin{bmatrix} \mathbf{N}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-1}^{(2)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(3)} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-1}^{(2)} + w_{13}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\
 \mathbf{W}_{t-1}^{(2)*} &= \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-1}^{(1)} + w_{23}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-1}^{(1)} + w_{32}\mathbf{N}_{t-1}^{(2)} \end{bmatrix}, \quad \mathbf{N}_{t-2}^{(1)*} = \begin{bmatrix} \mathbf{N}_{t-2}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},
 \end{aligned}$$

$$\mathbf{N}_{t-2}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-2}^{(2)} \\ \mathbf{0} \end{bmatrix}, \mathbf{N}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-2}^{(3)} \end{bmatrix}, \mathbf{W}_{t-2}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-2}^{(2)} + w_{13}\mathbf{N}_{t-2}^{(3)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{W}_{t-2}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-2}^{(1)} + w_{23}\mathbf{N}_{t-2}^{(3)} \\ \mathbf{0} \end{bmatrix}, \mathbf{W}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-2}^{(1)} + w_{32}\mathbf{N}_{t-2}^{(2)} \end{bmatrix}, \text{ dan } \hat{\mathbf{N}}_t = \begin{bmatrix} \hat{\mathbf{N}}_t^{(1)} \\ \hat{\mathbf{N}}_t^{(2)} \\ \hat{\mathbf{N}}_t^{(3)} \end{bmatrix}.$$


Banyaknya *neuron* adalah 1, 2, 3, 4, 5, 10, dan 15 dengan fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang dipilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Hasil evaluasi model untuk data simulasi 1 ditampilkan pada Tabel 4.18.

Tabel 4.18 Nilai Kebaikan Model *hybrid* GSTARX-FFNN Data Simulasi 1 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	2,397	2,318	2,175	2,979	2,658	2,542
GSTARX-FFNN (12,2,1)	2,689	2,490	2,624	3,171	2,606	2,897
GSTARX-FFNN (12,3,1)*	3,157	2,301	2,611	3,026	2,283	2,437
GSTARX-FFNN (12,4,1)	3,134	2,851	2,547	3,816	2,837	2,891
GSTARX-FFNN (12,5,1)	2,826	2,330	2,433	3,233	2,700	2,683
GSTARX-FFNN (12,10,1)	2,700	2,814	2,794	3,074	2,682	2,713
GSTARX-FFNN (12,15,1)	2,694	2,582	3,316	3,126	2,663	2,751

Ket: *model terbaik

Berdasarkan Tabel 4.18, pemilihan model terbaik dilakukan berdasarkan kriteria data *testing*. Namun, terdapat perbedaan kesimpulan yang diperoleh untuk setiap lokasi. Dengan demikian, model terbaik yang dipilih merupakan model yang memiliki nilai minimum paling banyak di ketiga lokasi. Model *hybrid* GSTARX-FFNN dengan 12 *input*, 3 unit *neuron* yang dapat dinotasikan *hybrid* GSTARX-FFNN(12,3,1) merupakan model yang menghasilkan kesalahan ramalan terkecil. Untuk mengetahui apakah model *hybrid* GSTARX-FFNN(12,3,1) mampu menangkap pola data yang mengandung komponen tren, musiman, variasi kalender, dan *noise* nonlinier berikut ditampilkan *time series plot* hasil ramalan dan data aktual.



Gambar 4.29 Time Series Plot Data Aktual dan Ramalan Simulasi 1 Hybrid GSTARX-FFNN

Terlihat bahwa data ramalan *in sample* dan *out sample* sudah dapat mengikuti pola data simulasi yang mengandung komponen tren, musiman, dan variasi kalender. Setelah diperoleh nilai tingkat kesalahan ramalan untuk masing-masing data simulasi (Lampiran 31-40), model *hybrid* GSTARX-FFNN terbaik untuk setiap data simulasi disajikan pada 4.19.

Tabel 4.19 Nilai Keباikan Model Hybrid GSTARX-FFNN pada Skenario II

Data Simulasi	Model	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
1	GSTARX-FFNN (12,3,1)	3,157	2,301	2,611	3,026	2,283	2,437
2	GSTARX-FFNN (12,1,1)	3,501	3,478	3,540	1,753	1,688	1,572
3	GSTARX-FFNN (12,15,1)	2,471	2,440	2,151	1,772	1,304	1,361
4	GSTARX-FFNN (12,2,1)	2,456	2,217	2,003	2,544	1,953	2,345


Tabel 4.19 Nilai Kebaikan Model *Hybrid* GSTARX-FFNN pada Skenario II (lanjutan)

Data Simulasi	Model	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
5	GSTARX-FFNN (12,15,1)	2,947	2,313	1,983	1,732	2,176	1,101
6	GSTARX-FFNN (12,5,1)	2,789	2,597	3,259	1,704	1,159	1,680
7	GSTARX-FFNN (12,3,1)	3,185	3,218	2,664	1,257	1,199	1,250
8	GSTARX-FFNN (12,4,1)	2,498	2,149	2,149	2,717	2,670	2,864
9	GSTARX-FFNN (12,15,1)	3,647	2,846	3,476	1,756	1,911	2,063
10	GSTARX-FFNN (12,2,1)	2,781	2,286	2,146	1,380	1,289	2,018

Tabel 4.19 merupakan model terbaik untuk setiap data simulasi dengan menggunakan *hybrid* GSTARX-FFNN. Jumlah *neuron* untuk masing-masing model terbaik pada setiap replikasi berbeda-beda sehingga dalam menentukan jumlah neuron optimum menggunakan konsep *trial and error*.

Pemodelan Tahap Kedua Menggunakan GSTAR-DLNN

Pada pemodelan *hybrid* GSTAR-DLNN skenario II, *input* yang digunakan pada data simulasi 1 adalah variabel model GSTAR(2₁) yang terdiri dari 12 variabel. Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* pada *hidden layer* pertama adalah 1, 2, 3, 4, 5, 10, dan 15, sedangkan *hidden layer* kedua jumlah neuron yang digunakan adalah 1, 2, 3, 4, 5. Fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Berikut ini adalah arsitektur pemodelan *hybrid* GSTAR-DLNN pada skenario II.



Gambar 4.30 Arsitektur GSTAR-DLNN dengan 12 *Input* dan 1 *Hidden Layer*

dengan,


$$\begin{aligned}
\mathbf{N}_{t-1}^{(1)*} &= \begin{bmatrix} \mathbf{N}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-1}^{(2)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(3)} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-1}^{(2)} + w_{13}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\
\mathbf{W}_{t-1}^{(2)*} &= \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-1}^{(1)} + w_{23}\mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-1}^{(1)} + w_{32}\mathbf{N}_{t-1}^{(2)} \end{bmatrix}, \quad \mathbf{N}_{t-2}^{(1)*} = \begin{bmatrix} \mathbf{N}_{t-2}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\
\mathbf{N}_{t-2}^{(2)*} &= \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-2}^{(2)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-2}^{(3)} \end{bmatrix}, \quad \mathbf{W}_{t-2}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-2}^{(2)} + w_{13}\mathbf{N}_{t-2}^{(3)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \\
\mathbf{W}_{t-2}^{(2)*} &= \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-2}^{(1)} + w_{23}\mathbf{N}_{t-2}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-2}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-2}^{(1)} + w_{32}\mathbf{N}_{t-2}^{(2)} \end{bmatrix}, \quad \text{dan } \hat{\mathbf{N}}_t = \begin{bmatrix} \hat{\mathbf{N}}_t^{(1)} \\ \hat{\mathbf{N}}_t^{(2)} \\ \hat{\mathbf{N}}_t^{(3)} \end{bmatrix}.
\end{aligned}$$

Setelah diperoleh nilai tingkat kesalahan peramalan untuk masing-masing data simulasi (Lampiran 31-40), model *hybrid* GSTARX-DLNN terbaik untuk setiap data simulasi pada skenario II disajikan pada 4.20.

Tabel 4.20 Nilai Kebaikan Model *Hybrid* GSTARX-DLNN pada Skenario II

Data Simulasi	Model	RMSE <i>in sample</i>			RMSE <i>out sample</i>		
		Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
1	GSTARX-DLNN (12,10,4,1)	2,941	2,653	2,795	2,671	2,025	2,427
2	GSTARX-DLNN (12,10,2,1)	3,605	3,780	3,455	1,666	1,613	1,524
3	GSTARX-DLNN (12,1,1,1)	2,575	2,334	2,370	2,095	1,773	1,477
4	GSTARX-DLNN (12,5,3,1)	2,372	2,171	2,183	2,086	1,645	2,305
5	GSTARX-DLNN (12,10,2,1)	3,030	2,242	1,962	1,790	2,241	1,155
6	GSTARX-DLNN (12,15,2,1)	3,488	2,903	2,759	1,593	1,037	1,877
7	GSTARX-DLNN (12,15,5,1)	2,936	2,805	2,280	1,154	1,085	0,914
8	GSTARX-DLNN (12,4,2,1)	2,497	2,173	2,230	2,395	2,520	2,548
9	GSTARX-DLNN (12,15,5,1)	3,473	3,182	3,320	1,710	1,866	1,867
10	GSTARX-DLNN (12,5,3,1)	2,754	2,415	2,011	1,324	1,106	1,760

Berdasarkan Tabel 4.20 masing-masing model terbaik memiliki arsitektur yang berbeda-beda, maka dari itu diperlukan *trial and error* untuk mendapatkan arsitektur yang menghasilkan akurasi ramalan optimum. Selanjutnya akan ditampilkan *time series plot* ramalan model *hybrid* GSTARX-DLNN pada data simulasi 1 skenario II.




Gambar 4.31 Time Series Plot Data Aktual dan Ramalan Simulasi 1 Hybrid GSTARX-DLNN

Terlihat pada Gambar 4.31 data ramalan sudah dapat mengikuti pola data aktual yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* nonlinier.


c. Perbandingan Model VARX, GSTARX, dan Hybrid GSTARX-ANN pada Skenario II

Data simulasi pada skenario II merupakan data *space time* yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* nonlinier. Setelah dilakukan pemodelan dengan menggunakan model VARX, GSTARX dan *hybrid* GSTARX-ANN, kemudian dilakukan perbandingan akurasi ramalan berdasarkan kriteria RMSE terkecil pada data *out sample*.




Gambar 4.32 Box Plot Nilai RMSE di Tiga Lokasi pada Skenario II

Pada Gambar 4.32, terlihat jelas bahwa pada skenario II model *hybrid* GSTARX-FFNN dan *hybrid* GSTARX-DLNN memberikan hasil ramalan yang lebih akurat dibandingkan GSTARX dan VARX, terlihat dari median dan *mean* dari RMSE model *hybrid* yang lebih kecil dibandingkan model GSTARX maupun VARX di ketiga lokasi. Kedalaman arsitektur pada model *hybrid* GSTARX-DLNN tidak memberikan pengaruh yang cukup signifikan dalam mengurangi tingkat kesalahan ramalan dibandingkan model *hybrid* GSTARX-FFNN. Hal ini sesuai dengan kesimpulan pertama M3 competition bahwa metode yang canggih atau rumit secara statistik tidak serta merta menghasilkan ramalan yang lebih akurat daripada yang sederhana. Maka dapat disimpulkan bahwa dalam pemilihan arsitektur yang menghasilkan akurasi ramalan optimum, diperlukan konsep *trial and error*.



Gambar 4.33 Line Plot Nilai RMSE Out Sample Skenario II di Tiga Lokasi

Berdasarkan Gambar 4.33, pada lokasi 1 dan 2 dari 10 replikasi model *hybrid* GSTARX-DLNN menghasilkan kesalahan ramalan terkecil sebanyak 8 replikasi sedangkan model *hybrid* GSTARX-FFNN sebanyak 2 replikasi. Pada lokasi 3, model *hybrid* GSTARX-FFNN menghasilkan kesalahan ramalan terkecil sebanyak 3 replikasi dan *hybrid* GSTARX-DLNN sebanyak 7 replikasi. Selanjutnya, penjabaran model terbaik di masing-masing lokasi pada skenario II ditampilkan pada Gambar 4.34.



Gambar 4.34 Model Terbaik Data Simulasi Skenario II

Dengan demikian, model *hybrid* GSTARX-ANN merupakan model terbaik dalam meramalkan data yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* nonlinier, sesuai dengan karakteristik *neural network* yang dapat menangkap pola nonlinieritas.

4.2 Pemodelan Data *Inflow* dan *Outflow* di Jawa Timur

Pemodelan *inflow* dan *outflow* uang kartal di Jawa Timur terdiri dari empat Kantor Perwakilan Bank Indonesia (KPw BI), yaitu Surabaya, Malang, Kediri, dan Jember. Data yang digunakan merupakan data bulanan periode Januari 2003 sampai Desember 2014. Data periode Januari 2003 sampai Desember 2013 sebagai data *in sample* sedangkan data periode Januari 2014 sampai dengan Desember 2014 sebagai data *out sample*.

Pemodelan *inflow* dan *outflow* dilakukan secara dua tahap. Tahap pertama memodelkan pola tren, musiman, dan variasi kalender menggunakan *Time Series Regression* (TSR) dengan metode estimasi adalah GLS. Tahap kedua dilakukan pemodelan residual tahap pertama dengan VAR, GSTAR, *hybrid* GSTAR-FFNN, dan *hybrid* GSTAR-DLNN. Sebelum melakukan pemodelan, dilakukan eksplorasi data untuk mengetahui karakteristik *inflow* dan *outflow* di masing-masing KPw BI wilayah Jawa Timur.

4.2.1 Karakteristik Data *Inflow* dan *Outflow* di KPw BI Jawa Timur


Berikut ini disajikan deskripsi data *inflow* dan *outflow* di masing-masing KPw BI Jawa Timur.

Tabel 4.21 Statistika Deskriptif (miliar Rp) Data *Inflow* dan *Outflow* di KPw BI Jawa Timur


Data	KPw BI	Mean	Standar Deviasi	Minimum	Maksimum
<i>Inflow</i>	Surabaya	1501,395	973,958	179,258	7006,259
	Malang	660,647	433,865	110,721	3107,357
	Kediri	575,036	377,708	58,691	2673,339
	Jember	405,076	221,610	129,168	1552,023
<i>Outflow</i>	Surabaya	1387,816	1072,796	43,087	6489,123
	Malang	398,203	340,913	5,042	2932,614
	Kediri	592,110	475,015	5,471	3286,356
	Jember	303,321	232,883	5,272	1733,124

Berdasarkan Tabel 4.21, rata-rata *inflow* tertinggi di KPw BI Surabaya, yaitu sebesar 1501,395 miliar dengan standar deviasi sebesar 973,958 dan rata-

rata terendah di KPw BI Jember sebesar 405,076 miliar dengan standar deviasi sebesar 221,61. Begitu juga dengan data *outflow*, rata-rata tertinggi di KPw BI Surabaya sebesar 1387,816 miliar dengan standar deviasi sebesar 1072,796 dan rata-rata *outflow* terendah di KPw BI Jember sebesar 303,321 miliar dengan standar deviasi sebesar 232,883. Gambar 4.35 menunjukkan perkembangan *inflow* dan *outflow* dari tahun 2003 sampai 2014 di masing-masing KPw BI Jawa Timur.



Gambar 4.35 Plot Time Series Data *Inflow* (kiri) dan *Outflow* (kanan) di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember



Data *inflow* dan *outflow* uang kartal di masing-masing KPw BI Jawa


- i. Tren 1, periode 2003 sampai 2006.
- ii. Tren 2, periode 2007 sampai 2010.
- iii. Tren 3, periode 2011 sampai 2014.

Pada tahun 2011 terdapat kebijakan baru tentang mata uang yaitu UU No.7 tahun 2011 yang bertujuan untuk menegaskan Rupiah sebagai mata uang Republik Indonesia beserta seluruh informasi tentang fisik dan penggunaan serta sanksi terhadap penyelewengan, penyalahgunaan Rupiah dalam transaksi bisnis dan pembayaran di Republik Indonesia. Setelah diberlakukannya UU No.7 tahun 2011, *inflow* dan *outflow* uang kartal di masing-masing KPw BI Jawa Timur mulai mengalami peningkatan dari tahun ke tahun. Maka dari itu, dalam pemodelan *inflow* dan *outflow* perlu dimasukkan pengaruh kebijakan BI sebagai *dummy* tren.

tiap tahunnya. Hal ini diduga karena pengaruh lebaran hari raya Idul Fitri yang berubah-ubah tiap tahunnya pada kalender Masehi sehingga *inflow* dan *outflow* tinggi pada bulan-bulan tertentu.

Sebagai contoh pada tahun 2003, lebaran Idul Fitri terjadi pada bulan November minggu IV, hal ini menyebabkan *outflow* tertinggi pada masing-masing KPw BI Jawa Timur tahun 2003 yaitu pada bulan November. Fenomena masyarakat yang membutuhkan uang untuk keperluan hari raya membuat aliran uang yang keluar dari kas BI semakin besar. Sedangkan *inflow* tertinggi untuk masing-masing KPw BI di Jawa Timur terjadi pada bulan Desember, hal ini diduga karena perilaku masyarakat yang menabung uangnya setelah hari raya.

Efek minggu terjadinya lebaran Idul Fitri juga memengaruhi tingginya *inflow* dan *outflow* pada bulan tertentu. Sebagai contoh, lebaran Idul Fitri pada tahun 2005 yang terjadi pada minggu I bulan November, menyebabkan *outflow* tinggi pada bulan Oktober, sedangkan *inflow* tinggi pada bulan November. Berikut ini disajikan pengaruh minggu terjadinya lebaran Idul Fitri terhadap *inflow* dan *outflow* di masing-masing KPw BI Jawa Timur.




Gambar 4.36 Pengaruh Minggu Terhadap Rata-rata *Inflow* Uang Kartal Saat dan Satu Bulan Setelah Hari Raya Idul Fitri di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember

Berdasarkan Gambar 4.36 dapat disimpulkan pengaruh minggu terjadinya hari raya Idul Fitri terhadap rata-rata *inflow* pada bulan dan satu bulan setelah terjadinya hari raya Idul Fitri, sebagai berikut

- Apabila hari raya Idul Fitri terjadi pada minggu pertama dan kedua maka rata-rata *inflow* tinggi pada bulan terjadinya hari raya Idul Fitri.
- Apabila hari raya Idul Fitri terjadi pada minggu ketiga dan keempat maka rata-rata *inflow* pada saat hari raya Idul Fitri tidak lebih tinggi dibandingkan satu bulan setelah hari raya Idul Fitri.

Berdasarkan kesimpulan di atas, maka dalam pemodelan *inflow* diperlukan model variasi kalender yang memasukkan pengaruh bulan dan satu bulan setelah hari raya Idul Fitri dan minggu terjadinya hari raya Idul Fitri dalam bulan tersebut.



Gambar 4.37 Pengaruh Minggu Terhadap Rata-rata *Outflow* Uang Kartal Saat dan Satu Bulan Sebelum Hari Raya Idul Fitri di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember

Berdasarkan Gambar 4.37 pengaruh minggu terjadinya hari raya Idul Fitri terhadap pola kenaikan *outflow* sebagai berikut

- Apabila hari raya Idul Fitri terjadi pada minggu pertama dan kedua maka rata-rata *outflow* pada bulan tersebut tidak lebih tinggi dibandingkan satu bulan sebelum hari raya Idul Fitri.

- b. Apabila hari raya Idul Fitri terjadi pada minggu ketiga dan keempat maka rata-rata *outflow* tinggi pada bulan saat terjadinya Idul Fitri.


Sehingga dalam pemodelan *outflow* diperlukan model variasi kalender yang memasukkan pengaruh bulan dan satu bulan sebelum terjadinya hari raya Idul Fitri beserta minggu terjadinya hari raya Idul Fitri dalam bulan tersebut.

Selanjutnya ingin diketahui apakah data *inflow* dan *outflow* di KPw BI wilayah Jawa Timur ada unsur *neglected nonlinearity* dengan melakukan uji Terasvirta data terhadap periode waktu (t) yang disajikan pada Tabel 4.22.

Tabel 4.22 Hasil Uji Terasvirta Data *Inflow Outflow* Terhadap Periode Waktu (t)

Data	χ^2	df	P-value
<i>Inflow</i> Surabaya	11,174	2	3,747e-03
<i>Inflow</i> Malang	42,709	2	5,319e-10
<i>Inflow</i> Kediri	48,496	2	2,946e-11
<i>Inflow</i> Jember	38,032	2	5,515e-09
<i>Outflow</i> Surabaya	24,494	2	4,799e-06
<i>Outflow</i> Malang	15,241	2	4,902e-04
<i>Outflow</i> Kediri	9,441	2	8,911e-03
<i>Outflow</i> Jember	11,027	2	4032 e-03

Berdasarkan Tabel 4.22 untuk semua data *inflow* dan *outflow* nilai P-value lebih kecil dari α , diperjelas dengan matriks plot data pada Gambar 4.38 yang pola datanya tidak linier, hal ini berarti data *inflow* dan *outflow* di KPw BI Jawa Timur mengandung unsur *nonlinearity*, sehingga dimungkinkan dibangun model *hybrid* untuk menangkap pola data nonlinier.



Gambar 4.38 Matriks Plot Data (a) *Inflow* dan (b) *Outflow*

4.2.2 Pemodelan *Inflow* Tahap Pertama

Pemodelan *inflow* tahap pertama yaitu pemodelan tren, musiman, dan variasi kalender dengan menggunakan *time series regression* dan metode estimasi yang digunakan adalah GLS. Berikut hasil estimasi parameter pemodelan tren, musiman, dan variasi kalender data *inflow* di masing-masing KPw BI Jawa Timur.

Tabel 4.23 Estimasi Parameter Tahap I *Inflow* di KPw BI Jawa Timur

KPw BI	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
Surabaya	t	1	15,811	3,072	5,15	<0,0001
	D ₁	1	-1206,390	159,757	-7,55	<0,0001
	D ₂	1	-975,652	288,588	-3,38	0,0010
	S ₁	1	1729,705	179,819	9,62	<0,0001
	S ₂	1	1028,423	181,024	5,68	<0,0001
	S ₃	1	752,701	182,273	4,13	<0,0001
	S ₄	1	868,184	183,566	4,73	<0,0001
	S ₅	1	824,170	184,900	4,46	<0,0001
	S ₆	1	695,441	186,275	3,73	0,0003
	S ₇	1	895,531	187,691	4,77	<0,0001
	S ₈	1	1045,937	190,206	5,50	<0,0001
	S ₉	1	986,284	196,377	5,02	<0,0001
	S ₁₀	1	1128,763	197,809	5,71	<0,0001
	S ₁₁	1	854,545	202,735	4,22	<0,0001
	S ₁₂	1	581,247	199,156	2,92	0,0042
	V _{1,t}	1	1792,436	386,489	4,64	<0,0001
	V _{2,t}	1	1888,169	273,212	6,91	<0,0001
	V _{3,t+1}	1	1131,392	229,690	4,93	<0,0001
	V _{4,t+1}	1	1883,416	316,980	5,94	<0,0001
Malang	t	1	6,197	1,121	5,53	<0,0001
	D ₁	1	-388,129	57,218	-6,78	<0,0001
	D ₂	1	-1267,960	260,004	-4,88	<0,0001
	tD ₂	1	10,078	2,328	4,33	<0,0001
	S ₁	1	564,204	64,889	8,69	<0,0001
	S ₂	1	389,024	65,260	5,96	<0,0001
	S ₃	1	340,576	65,648	5,19	<0,0001
	S ₄	1	296,978	66,053	4,50	<0,0001
	S ₅	1	261,141	66,474	3,93	0,0001
	S ₆	1	215,143	66,912	3,22	0,0017
	S ₇	1	267,751	67,365	3,97	0,0001
	S ₈	1	327,482	68,277	4,80	<0,0001
	S ₉	1	321,091	70,096	4,58	<0,0001
	S ₁₀	1	324,745	70,609	4,60	<0,0001

Tabel 4.23 Estimasi Parameter Tahap I *Inflow* di KPw BI Jawa Timur (lanjutan)

KPw BI	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
Malang	S ₁₁	1	303,847	72,515	4,19	<0,0001
	S ₁₂	1	215,621	71,167	3,03	0,0030
	V _{1,t}	1	555,730	137,965	4,03	0,0001
	V _{2,t}	1	510,034	97,591	5,23	<0,0001
	V _{4,t+1}	1	594,026	113,520	5,23	<0,0001
Kediri	t	1	4,005	1,305	3,07	0,0027
	D ₂	1	-1166,780	230,781	-5,06	<0,0001
	tD ₁	1	-7,207	0,924	-7,80	<0,0001
	tD ₂	1	6,302	2,194	2,87	0,0049
	S ₁	1	799,105	60,357	13,24	<0,0001
	S ₂	1	530,987	60,758	8,74	<0,0001
	S ₃	1	466,131	61,171	7,62	<0,0001
	S ₄	1	492,137	61,596	7,99	<0,0001
	S ₅	1	504,816	62,034	8,14	<0,0001
	S ₆	1	410,014	62,482	6,56	<0,0001
	S ₇	1	505,069	62,943	8,02	<0,0001
	S ₈	1	600,645	63,827	9,41	<0,0001
	S ₉	1	528,534	65,903	8,02	<0,0001
	S ₁₀	1	464,027	66,392	6,99	<0,0001
	S ₁₁	1	427,812	67,693	6,32	<0,0001
	S ₁₂	1	419,388	66,607	6,30	<0,0001
	V _{1,t}	1	850,265	123,434	6,89	<0,0001
	V _{2,t}	1	730,718	87,390	8,36	<0,0001
	V _{2,t+1}	1	178,723	48,650	3,67	0,0004
	V _{3,t+1}	1	302,689	69,993	4,32	<0,0001
	V _{4,t+1}	1	762,897	101,536	7,51	<0,0001
Jember	t	1	5,494	0,818	6,71	<0,0001
	D ₂	1	-962,400	131,145	-7,34	<0,0001
	tD ₁	1	-4,680	0,580	-8,07	<0,0001
	tD ₂	1	4,858	1,231	3,95	0,0001
	S ₁	1	437,929	38,175	11,47	<0,0001
	S ₂	1	245,977	38,437	6,40	<0,0001
	S ₃	1	169,025	38,707	4,37	<0,0001
	S ₄	1	194,447	38,985	4,99	<0,0001
	S ₅	1	235,097	39,270	5,99	<0,0001
	S ₆	1	178,711	39,561	4,52	<0,0001
	S ₇	1	186,951	39,860	4,69	<0,0001
	S ₈	1	153,964	40,755	3,78	0,0003
	S ₉	1	165,086	41,583	3,97	0,0001

Tabel 4.23 Estimasi Parameter Tahap I *Inflow* di KPw BI Jawa Timur (lanjutan)

KPw BI	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
Jember	S_{10}	1	213,017	41,918	5,08	<0,0001
	S_{11}	1	173,849	42,982	4,04	<0,0001
	S_{12}	1	166,356	42,117	3,95	0,0001
	$V_{1,t}$	1	475,927	78,399	6,07	<0,0001
	$V_{2,t}$	1	385,597	55,447	6,95	<0,0001
	$V_{3,t}$	1	142,231	42,399	3,35	0,0011
	$V_{4,t}$	1	90,897	35,202	2,58	0,0111
	$V_{4,t+1}$	1	458,774	64,443	7,12	<0,0001

Berdasarkan uji signifikansi parameter pada Tabel 4.23 data *inflow* di masing-masing KPw BI wilayah Jawa Timur dipengaruhi oleh tren, *dummy* kebijakan BI, musiman, dan variasi kalender. Berikut adalah model tahap I data *inflow* di masing-masing KPw BI Jawa Timur.

KPw BI Surabaya

$$\begin{aligned}
 Z_t^{(1)} = & 15,811t - 1206,39D_{1,t} - 975,652D_{2,t} + 1729,705S_{1,t} + 1028,423S_{2,t} + \\
 & 752,701S_{3,t} + 868,184S_{4,t} + 824,17S_{5,t} + 695,441S_{6,t} + 895,531S_{7,t} + \\
 & 1045,937S_{8,t} + 986,284S_{9,t} + 1128,763S_{10,t} + 854,545S_{11,t} + 581,247S_{12,t} + \\
 & 1792,436V_{1,t} + 1888,169V_{2,t} + 1131,392V_{3,t+1} + 1883,416V_{4,t+1} + N_t^{(1)}.
 \end{aligned} \tag{4.7}$$

KPw BI Malang

$$\begin{aligned}
 Z_t^{(2)} = & 6,197t - 388,129D_{1,t} - 1267,96D_{2,t} + 10,078tD_{2,t} + 564,204S_{1,t} + \\
 & 389,024S_{2,t} + 340,576S_{3,t} + 296,978S_{4,t} + 261,141S_{5,t} + 215,143S_{6,t} + \\
 & 267,751S_{7,t} + 327,482S_{8,t} + 321,091S_{9,t} + 324,745S_{10,t} + 303,847S_{11,t} + \\
 & 215,621S_{12,t} + 555,73V_{1,t} + 510,034V_{2,t} + 594,026V_{4,t+1} + N_t^{(2)}.
 \end{aligned} \tag{4.8}$$

KPw BI Kediri

$$\begin{aligned}
 Z_t^{(3)} = & 4,005t - 1166,78D_{2,t} - 7,207tD_{1,t} + 6,302tD_{2,t} + 799,105S_{1,t} + \\
 & 530,987S_{2,t} + 466,131S_{3,t} + 492,137S_{4,t} + 504,816S_{5,t} + 410,014S_{6,t} + \\
 & 505,069S_{7,t} + 600,645S_{8,t} + 528,534S_{9,t} + 464,027S_{10,t} + 427,812S_{11,t} + \\
 & 419,388S_{12,t} + 850,265V_{1,t} + 730,718V_{2,t} + 178,723V_{2,t+1} + 302,689V_{3,t+1} + \\
 & 762,897V_{4,t+1} + N_t^{(3)}.
 \end{aligned} \tag{4.9}$$

KPw BI Jember

$$\begin{aligned}
Z_t^{(4)} = & 5,494t - 962,4D_{2,t} - 4,68tD_{1,t} + 4,858tD_{2,t} + 437,929S_{1,t} + 245,977S_{2,t} + \\
& 169,025S_{3,t} + 194,447S_{4,t} + 235,097S_{5,t} + 178,711S_{6,t} + 186,951S_{7,t} + \\
& 153,964S_{8,t} + 165,086S_{9,t} + 213,017S_{10,t} + 173,849S_{11,t} + 166,356S_{12,t} + \\
& 475,927V_{1,t} + 385,597V_{2,t} + 142,23V_{3,t} + 90,897V_{4,t} + 458,774V_{4,t+1} + N_t^{(4)}.
\end{aligned} \tag{4.10}$$

Berdasarkan persamaan (4.7)-(4.10), model tahap I data *inflow* di KPw BI Jawa Timur dapat disajikan dalam persamaan matriks sebagai berikut

$$\begin{aligned}
\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \\ Z_t^{(4)} \end{bmatrix} = & \begin{bmatrix} 15,811 & 0 & 0 & 0 \\ 0 & 6,197 & 0 & 0 \\ 0 & 0 & 4,005 & 0 \\ 0 & 0 & 0 & 5,494 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} 1206,39 & 0 & 0 & 0 \\ 0 & 388,129 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \\
& \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots + \begin{bmatrix} 1729,705 & 0 & 0 & 0 \\ 0 & 564,204 & 0 & 0 \\ 0 & 0 & 799,105 & 0 \\ 0 & 0 & 0 & 437,929 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots + \\
& \begin{bmatrix} 1131,392 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 302,689 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} V_{3,t+1}^{(1)} \\ V_{3,t+1}^{(2)} \\ V_{3,t+1}^{(3)} \\ V_{3,t+1}^{(4)} \end{bmatrix} + \\
& \begin{bmatrix} 1883,416 & 0 & 0 & 0 \\ 0 & 594,026 & 0 & 0 \\ 0 & 0 & 762,897 & 0 \\ 0 & 0 & 0 & 458,774 \end{bmatrix} \begin{bmatrix} V_{4,t+1}^{(1)} \\ V_{4,t+1}^{(2)} \\ V_{4,t+1}^{(3)} \\ V_{4,t+1}^{(4)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix}.
\end{aligned} \tag{4.11}$$

Selanjutnya dilakukan pemodelan tahap kedua yaitu memodelkan residual tahap pertama menggunakan VAR, GSTAR, dan *hybrid* GSTAR-ANN.


4.2.3 Pemodelan *Inflow* Tahap Kedua

Pemodelan *inflow* tahap kedua memodelkan residual tahap pertama menggunakan metode VAR, GSTAR, *hybrid* GSTAR-FFNN, dan *hybrid* GSTAR-DLNN. Berikut adalah pembahasan pemodelan *inflow* tahap kedua.

I. Pemodelan *Inflow* Tahap Kedua Menggunakan VAR

Langkah awal dalam pemodelan VAR adalah melakukan identifikasi residual data *inflow*. Identifikasi ini bertujuan untuk mengetahui apakah data yang

digunakan sudah stasioner atau tidak. Proses identifikasi stasioneritas secara visual dengan melihat *time series plot* yang ditampilkan pada Gambar 4.39. Selain itu, identifikasi stasioneritas juga dapat dilihat berdasarkan skematik MCCF. Berdasarkan Gambar 4.39, *time series plot* residual dari ketiga lokasi diduga sudah stasioner karena berada disekitar $\mu=0$.



Gambar 4.39 *Time Series Plot* Residual Tahap I Data *Inflow* di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember

Kemudian dilakukan pemeriksaan stasioneritas dari residual *inflow* melalui skematik MCCF dan pemeriksaan orde waktu (Ar) melalui skematik MPPCF dan nilai AIC sebagai berikut

Schematic Representation of Cross Correlations													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	++++
zresid2	++++--	+..
zresid3	+++++	+..
zresid4	++++	+..

Gambar 4.40 Representasi Skema MCCF untuk Residual Data *Inflow*

Skema MCCF pada Gambar 4.40 menunjukkan bahwa data sudah stasioner, hal ini terlihat dari banyaknya tanda (.) yang muncul. Sedangkan skema

MPCCF residual *inflow* signifikan pada lag 1. Berdasarkan plot MPCCF tersebut, dapat diketahui bahwa orde dari model yang diduga adalah VAR(1).

Variable/ Lag	Schematic Representation of Partial Cross Correlations											
	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	+-
zresid2	-+-
zresid3	-.	+	+	+	...	+
zresid4	..--	+	+

Gambar 4.41 Representasi Skematik MPCCF Residual Data *Inflow*

Selain melakukan pengecekan melalui plot MCCF dan MPCCF, perlu dilakukan pengecekan terhadap nilai AIC dari model.

Tabel 4.24 Nilai AIC Model VAR Residual Data *Inflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	38,502	38,552	38,650	38,666	38,829	38,926
AR 1	38,154	38,389	38,571	38,682	38,893	39,057
AR 2	38,295	38,503	38,692	38,888	39,069	39,260
AR 3	38,484	38,626	38,793	38,978	39,214	39,451
AR 4	38,576	38,765	38,971	39,166	39,330	39,590
AR 5	38,730	39,007	39,230	39,414	39,558	39,863
AR 6	39,001	39,404	39,661	39,889	40,078	40,441
AR 7	39,230	39,674	40,157	40,434	40,675	41,105
AR 8	39,431	39,922	40,458	41,049	41,347	41,858
AR 9	39,623	40,168	40,769	41,433	42,172	42,781
AR 10	39,992	40,602	41,279	42,032	42,877	43,831
AR 11	40,502	41,191	41,960	42,823	43,800	44,914
AR 12	40,843	41,627	42,509	43,509	44,652	45,971

Pada Tabel 4.24 menunjukkan bahwa nilai AIC terkecil dari model VAR adalah terletak di lag MA 0 dan AR 1. Hal ini sama seperti yang diduga oleh plot MPCCF yaitu VAR(1).

Hasil estimasi parameter model VAR(1) memiliki 16 parameter. Akan tetapi, jika dilihat dari nilai *p-value* masing-masing parameter dapat diketahui bahwa tidak semua parameter memiliki pengaruh yang signifikan terhadap model. Untuk mengatasi dilakukan *restrict* terhadap parameter tersebut. Perintah *restrict* dilakukan terhadap satu demi satu variabel yang tidak signifikan secara bertahap, sampai semua parameter signifikan. Pada pemodelan residual data *inflow* setelah dilakukan *restrict* terdapat lokasi yang semua parameternya tidak signifikan, sehingga model yang digunakan adalah *full model* (melibatkan semua parameter tanpa memperhatikan signifikansinya). Menurut Armstrong (2001) dalam

forecasting dapat menggunakan semua variabel untuk keperluan meningkatkan akurasi ramalan. Berikut hasil estimasi parameter model VAR(1)

Tabel 4.25 Estimasi Parameter *Full Model* VAR(1) *Inflow*

KPw BI	Parameter	Estimasi	Standar Error	t-value	P-value	Variabel
Surabaya	ϕ_{11}^1	0,477	0,151	3,16	0,0020	$N_{t-1}^{(1)}$
	ϕ_{12}^1	-0,988	0,453	-2,18	0,0309	$N_{t-1}^{(2)}$
	ϕ_{13}^1	-0,836	0,491	-1,70	0,0912	$N_{t-1}^{(3)}$
	ϕ_{14}^1	0,351	0,792	0,44	0,6588	$N_{t-1}^{(4)}$
Malang	ϕ_{21}^1	0,107	0,056	1,92	0,0575	$N_{t-1}^{(1)}$
	ϕ_{22}^1	0,369	0,168	2,20	0,0296	$N_{t-1}^{(2)}$
	ϕ_{23}^1	-0,410	0,182	-2,25	0,0259	$N_{t-1}^{(3)}$
	ϕ_{24}^1	-0,537	0,294	-1,83	0,0700	$N_{t-1}^{(4)}$
Kediri	ϕ_{31}^1	0,100	0,051	1,97	0,0505	$N_{t-1}^{(1)}$
	ϕ_{32}^1	-0,097	0,152	-0,64	0,5251	$N_{t-1}^{(2)}$
	ϕ_{33}^1	0,045	0,166	0,27	0,7843	$N_{t-1}^{(3)}$
	ϕ_{34}^1	-0,493	0,267	-1,85	0,0669	$N_{t-1}^{(4)}$
Jember	ϕ_{41}^1	0,086	0,032	2,69	0,0082	$N_{t-1}^{(1)}$
	ϕ_{42}^1	-0,036	0,096	-0,38	0,7072	$N_{t-1}^{(2)}$
	ϕ_{43}^1	-0,129	0,104	-1,24	0,2157	$N_{t-1}^{(3)}$
	ϕ_{44}^1	-0,150	0,168	-0,90	0,3714	$N_{t-1}^{(4)}$

Berdasarkan *full model* maka dapat dibentuk persamaan matematis model VARX(1) dalam bentuk matriks seperti berikut ini,

Persamaan tahap I

$$\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \\ Z_t^{(4)} \end{bmatrix} = \begin{bmatrix} 15,811 & 0 & 0 & 0 \\ 0 & 6,197 & 0 & 0 \\ 0 & 0 & 4,005 & 0 \\ 0 & 0 & 0 & 5,494 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} 1206,39 & 0 & 0 & 0 \\ 0 & 388,129 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \\
 + \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots + \begin{bmatrix} 1729,705 & 0 & 0 & 0 \\ 0 & 564,204 & 0 & 0 \\ 0 & 0 & 799,105 & 0 \\ 0 & 0 & 0 & 437,929 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots + \\
 \begin{bmatrix} 1883,416 & 0 & 0 & 0 \\ 0 & 594,026 & 0 & 0 \\ 0 & 0 & 762,897 & 0 \\ 0 & 0 & 0 & 458,774 \end{bmatrix} \begin{bmatrix} V_{4,t+1}^{(1)} \\ V_{4,t+1}^{(2)} \\ V_{4,t+1}^{(3)} \\ V_{4,t+1}^{(4)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} .$$

Persamaan tahap II

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,477 & -0,988 & -0,836 & 0,351 \\ 0,107 & 0,369 & -0,41 & -0,537 \\ 0,1 & -0,097 & 0,045 & -0,493 \\ 0,086 & -0,036 & -0,129 & -0,15 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Setelah melakukan estimasi parameter, langkah selanjutnya adalah melakukan pengujian asumsi *white noise*. Pengujian dilakukan dengan cara memodelkan ulang residual dari model. Selanjutnya dilakukan pengecekan dimana letak AIC terkecil. Jika letak AIC terkecil terdapat pada lag AR 0 dan MA 0, maka residual dapat dikatakan sudah memenuhi asumsi *white noise*.

Tabel 4.26 Nilai AIC Residual Model VAR Data *Inflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	37,903	38,266	38,429	38,522	38,682	38,778
AR 1	38,159	38,391	38,564	38,676	38,893	38,997
AR 2	38,358	38,566	38,756	38,892	39,071	39,179
AR 3	38,476	38,647	38,832	38,969	39,175	39,412
AR 4	38,634	38,848	39,004	39,123	39,449	39,717
AR 5	38,760	38,996	39,241	39,442	39,612	39,889
AR 6	39,010	39,419	39,694	39,928	40,139	40,478
AR 7	39,252	39,701	40,191	40,476	40,744	41,154
AR 8	39,502	39,999	40,544	41,145	41,478	41,974
AR 9	39,705	40,258	40,869	41,545	42,299	42,900
AR 10	40,051	40,672	41,361	42,130	42,993	43,969
AR 11	40,583	41,285	42,069	42,952	43,952	45,095

Berdasarkan Tabel 4.26, dapat diketahui bahwa nilai AIC terkecil terletak pada AR 0 dan MA 0. Hal ini menunjukkan bahwa residual sudah memenuhi asumsi *white noise*.

Selanjutnya, untuk mengetahui kebaikan model VARX dalam meramalkan data *inflow*, dihitung nilai kebaikan model *in sample* maupun *out sample* yang disajikan pada Tabel 4.27.


Tabel 4.27 Nilai Kebaikan Model VARX(1) Data *Inflow*

Data	KPw BI	Kriteria Kebaikan Model	
		RMSE	MAPE
<i>In Sample</i>	Surabaya	447,492	38,812
	Malang	165,871	24,332
	Kediri	150,728	36,362
	Jember	94,647	21,183


Tabel 4.27 Nilai Kebaikan Model VARX(1) Data *Inflow* (lanjutan)

Data	KPw BI	Kriteria Kebaikan Model	
		RMSE	MAPE
<i>Out Sample</i>	Surabaya	1065,051	58,600
	Malang	484,810	26,631
	Kediri	439,829	31,849
	Jember	196,940	21,819

Berdasarkan Tabel 4.27 menunjukkan bahwa nilai RMSE KPw BI yang rata-rata *inflow*-nya lebih besar akan cenderung semakin besar. Dengan demikian, perbandingan antar KPw BI sebaiknya dilakukan menggunakan kriteria yang berbasis persentase, misalnya MAPE. Nilai MAPE untuk masing-masing KPw BI wilayah Jawa Timur relatif besar. Selanjutnya dilakukan perbandingan data aktual dan ramalan untuk setiap KPw BI. Perbandingan dilakukan pada data *in sample* dan *out sample* ditunjukkan pada gambar berikut



Gambar 4.42 Perbandingan Data Aktual dan Ramalan Model VARX KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember



Gambar 4.42 Perbandingan Data Aktual dan Ramalan Model VARX KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember (lanjutan)

Berdasarkan Gambar 4.42, terlihat bahwa hasil ramalan data *inflow* di masing-masing KPw BI wilayah Jawa Timur sudah dapat menangkap pola variasi kalender, tetapi masih ada jarak yang cukup lebar antara data ramalan dan aktual.

II. Pemodelan *Inflow* Tahap Kedua Menggunakan GSTAR

Dalam pemodelan GSTAR, orde model yang digunakan sama dengan orde VAR, yaitu GSTAR(1₁). Bobot lokasi yang digunakan dalam pemodelan GSTAR yaitu bobot seragam, invers jarak, dan normalisasi inferensi korelasi silang parsial. Estimasi parameter yang digunakan dalam pemodelan adalah GLS. Model yang digunakan adalah *full model* yaitu semua parameter digunakan tanpa memperhatikan signifikansinya dikarenakan pemodelan dengan *restrict* terdapat lokasi yang semua parameternya tidak signifikan. Berikut adalah pembahasan untuk masing-masing bobot yang digunakan.

a. Bobot Seragam

Penerapan bobot seragam pada pemodelan GSTAR mengasumsikan bahwa masing-masing data *inflow* di KPw BI wilayah Jawa Timur memiliki

keterkaitan yang sama sehingga pemberian bobot untuk lokasi ke- i dan j adalah sama. Matriks bobot seragam pada model GSTAR(1₁) sebagai berikut

$$\mathbf{W} = \begin{bmatrix} 0,00 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0,00 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0,00 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0,00 \end{bmatrix}.$$

Berikut adalah hasil estimasi parameter GSTAR (1₁) residual data *inflow*,

Tabel 4.28 Estimasi Parameter Bobot Seragam Residual *Inflow*

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Surabaya	ϕ_{10}^1	1	0,233	0,089	2,61	0,0101
	ϕ_{11}^1	1	-0,929	0,318	-2,92	0,0041
Malang	ϕ_{20}^1	1	0,371	0,079	4,72	<0,0001
	ϕ_{21}^1	1	-0,228	0,074	-3,08	0,0030
Kediri	ϕ_{30}^1	1	0,262	0,083	3,14	0,0021
	ϕ_{31}^1	1	-0,170	0,068	-2,49	0,0139
Jember	ϕ_{40}^1	1	-0,098	0,092	-1,06	0,2893
	ϕ_{41}^1	1	0,051	0,045	1,14	0,2551

Berdasarkan parameter model pada Tabel 4.28, dapat disajikan dalam bentuk persamaan matriks model GSTAR(1₁) sebagai berikut:

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,233 & 0 & 0 & 0 \\ 0 & 0,371 & 0 & 0 \\ 0 & 0 & 0,262 & 0 \\ 0 & 0 & 0 & -0,098 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} -0,929 & 0 & 0 & 0 \\ 0 & -0,228 & 0 & 0 \\ 0 & 0 & -0,17 & 0 \\ 0 & 0 & 0 & 0,051 \end{bmatrix} \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Persamaan matriks model GSTAR(1₁) di atas, dapat disajikan dalam persamaan di masing-masing KPw BI sebagai berikut

Model GSTAR (1₁) di KPw BI Surabaya

$$N_t^{(1)} = 0,233N_{t-1}^{(1)} - 0,309N_{t-1}^{(2)} - 0,309N_{t-1}^{(3)} - 0,309N_{t-1}^{(4)} + a_t^{(1)}.$$

Model GSTAR (1₁) di KPw BI Malang

$$N_t^{(2)} = 0,371N_{t-1}^{(2)} - 0,076N_{t-1}^{(1)} - 0,076N_{t-1}^{(3)} - 0,076N_{t-1}^{(4)} + a_t^{(2)}.$$

Model GSTAR (1₁) di KPw BI Kediri

$$N_t^{(3)} = 0,262N_{t-1}^{(3)} - 0,057N_{t-1}^{(1)} - 0,057N_{t-1}^{(2)} - 0,057N_{t-1}^{(4)} + a_t^{(3)}.$$

Model GSTAR (1₁) di KPw BI Jember

$$N_t^{(4)} = -0,098N_{t-1}^{(4)} + 0,017N_{t-1}^{(1)} + 0,017N_{t-1}^{(2)} + 0,017N_{t-1}^{(3)} + a_t^{(4)}.$$

Kemudian dilakukan pengujian asumsi *white noise*. Pengujian dilakukan dengan cara memodelkan ulang residual dari model, jika letak AIC terkecil terdapat pada lag AR 0 dan MA 0, maka residual dapat dikatakan sudah memenuhi asumsi *white noise*.

Tabel 4.29 Nilai AIC Residual Model GSTAR Bobot Seragam Data *Inflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	38,119	38,331	38,453	38,525	38,709	38,796
AR 1	38,213	38,440	38,608	38,708	38,916	39,048
AR 2	38,345	38,566	38,778	38,913	39,117	39,219
AR 3	38,442	38,614	38,805	39,007	39,248	39,440
AR 4	38,618	38,812	39,010	39,186	39,554	39,715
AR 5	38,754	39,002	39,248	39,436	39,590	39,872
AR 6	39,016	39,424	39,698	39,924	40,115	40,462

Berdasarkan Tabel 4.29, terlihat nilai AIC terkecil terletak pada AR 0 dan MA 0 maka dapat dikatakan residual sudah memenuhi asumsi *white noise*.

b. Bobot Invers Jarak

Pemodelan GSTAR(1₁) dengan menggunakan bobot invers jarak mengasumsikan bahwa data *inflow* di masing-masing KPw BI wilayah Jawa Timur dipengaruhi oleh jarak lokasi antar KPw. Jarak antara dua lokasi yang lebih jauh memiliki bobot yang lebih kecil dibandingkan dengan jarak antara dua lokasi yang lebih dekat. Matriks bobot invers jarak yang digunakan sebagai berikut

$$\mathbf{W} = \begin{bmatrix} 0 & 0,45 & 0,33 & 0,22 \\ 0,40 & 0 & 0,39 & 0,21 \\ 0,35 & 0,47 & 0 & 0,18 \\ 0,35 & 0,38 & 0,27 & 0 \end{bmatrix}.$$

Hasil estimasi parameter GSTAR (1₁) residual data *inflow* dengan bobot invers jarak sebagai berikut

Tabel 4.30 Estimasi Parameter Bobot Invers Jarak Residual *Inflow*

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Surabaya	ϕ_{10}^1	1	0,242	0,086	2,81	0,0057
	ϕ_{11}^1	1	-0,925	0,282	-3,28	0,0014
Malang	ϕ_{20}^1	1	0,348	0,079	4,43	<0,0001
	ϕ_{21}^1	1	-0,188	0,064	-2,94	0,0039
Kediri	ϕ_{30}^1	1	0,257	0,084	3,04	0,0029
	ϕ_{31}^1	1	-0,155	0,065	-2,38	0,0188
Jember	ϕ_{40}^1	1	-0,086	0,092	-0,93	0,3542
	ϕ_{41}^1	1	0,045	0,044	1,03	0,3059

Berdasarkan parameter pada Tabel 4.30, dapat disajikan dalam bentuk persamaan matriks model GSTAR(1₁) sebagai berikut:

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,242 & 0 & 0 & 0 \\ 0 & 0,348 & 0 & 0 \\ 0 & 0 & 0,257 & 0 \\ 0 & 0 & 0 & -0,086 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} -0,925 & 0 & 0 & 0 \\ 0 & -0,188 & 0 & 0 \\ 0 & 0 & -0,155 & 0 \\ 0 & 0 & 0 & 0,045 \end{bmatrix} \begin{bmatrix} 0 & 0,45 & 0,33 & 0,22 \\ 0,40 & 0 & 0,39 & 0,21 \\ 0,35 & 0,47 & 0 & 0,18 \\ 0,35 & 0,38 & 0,27 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Persamaan matriks model GSTAR(1₁) di atas, dapat disajikan dalam persamaan di masing-masing KPw BI sebagai berikut

Model GSTAR (1₁) di KPw BI Surabaya

$$N_t^{(1)} = 0,242N_{t-1}^{(1)} - 0,416N_{t-1}^{(2)} - 0,305N_{t-1}^{(3)} - 0,204N_{t-1}^{(4)} + a_t^{(1)}.$$

Model GSTAR (1₁) di KPw BI Malang

$$N_t^{(2)} = 0,348N_{t-1}^{(2)} - 0,075N_{t-1}^{(1)} - 0,073N_{t-1}^{(3)} - 0,039N_{t-1}^{(4)} + a_t^{(2)}.$$

Model GSTAR (1₁) di KPw BI Kediri

$$N_t^{(3)} = 0,257N_{t-1}^{(3)} - 0,054N_{t-1}^{(1)} - 0,073N_{t-1}^{(2)} - 0,028N_{t-1}^{(4)} + a_t^{(3)}.$$

Model GSTAR (1₁) di KPw BI Jember

$$N_t^{(4)} = -0,086N_{t-1}^{(4)} + 0,016N_{t-1}^{(1)} + 0,017N_{t-1}^{(2)} + 0,012N_{t-1}^{(3)} + a_t^{(4)}.$$

Kemudian dilakukan pengujian asumsi *white noise* dengan cara memodelkan ulang residual dari model, jika letak AIC terkecil terdapat pada lag AR 0 dan MA 0, maka residual sudah memenuhi asumsi *white noise*.

Tabel 4.31 Nilai AIC Residual Model GSTAR Bobot Invers jarak Data *Inflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	38,111	38,328	38,449	38,523	38,705	38,793
AR 1	38,207	38,429	38,601	38,705	38,914	39,045
AR 2	38,342	38,558	38,761	38,899	39,105	39,210
AR 3	38,443	38,616	38,800	38,996	39,236	39,429
AR 4	38,619	38,814	39,006	39,173	39,544	39,696
AR 5	38,757	39,004	39,247	39,428	39,585	39,869
AR 6	39,017	39,426	39,696	39,915	40,110	40,460

Terlihat pada Tabel 4.31 nilai AIC terkecil terletak pada AR 0 dan MA 0 sehingga residual sudah memenuhi asumsi *white noise*.

c. Bobot Normalisasi Inferensi Korelasi Silang Parsial

Pemodelan GSTAR(1₁) dengan menggunakan bobot normalisasi inferensi korelasi silang parsial (NIKSP) dilakukan dengan melihat nilai tinggi rendahnya korelasi silang parsial antar lokasi pada data.

Variable/ Lag	Schematic Representation of Partial Cross Correlations											
	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	+
zresid2	-	+
zresid3	-	+	+	...	+
zresid4	-	+	+	+

Gambar 4.43 Sekmatik Korelasi Silang Parsial antar Lokasi Residual *Inflow*

Hasil perhitungan korelasi silang parsial antar lokasi pada lag 1, $r_{ij}=1$ dengan $i, j=1,2,3,4$ dan $i \neq j$ dapat dilihat pada Tabel 4.31. Taksiran interval yang digunakan untuk perhitungan batas bawah dan batas atas parsial silang korelasi adalah 95%, disajikan pada Tabel berikut

Tabel 4.32 Taksiran Normalisasi Inferensi Korelasi Silang Parsial antar Lokasi

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$r_{12}(1)$	-0,02014	-0,19074	0,150456	Tidak Valid
$r_{13}(1)$	-0,05948	-0,23008	0,111116	Tidak Valid
$r_{14}(1)$	0,09614	-0,07446	0,266736	Tidak Valid
$r_{21}(1)$	-0,32745	-0,49805	-0,156850	Valid
$r_{23}(1)$	-0,09443	-0,26503	0,076166	Tidak Valid
$r_{24}(1)$	0,05084	-0,11976	0,221436	Tidak Valid
$r_{31}(1)$	-0,23026	-0,40086	-0,059660	Valid
$r_{32}(1)$	-0,16423	-0,33483	0,006366	Tidak Valid
$r_{34}(1)$	0,02081	-0,14979	0,191406	Tidak Valid

Tabel 4.32 Taksiran Normalisasi Inferensi Korelasi Silang Parsial antar Lokasi (lanjutan)

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$r_{41}(1)$	0,08267	-0,08793	0,253266	Tidak Valid
$r_{42}(1)$	-0,15282	-0,32342	0,017776	Tidak Valid
$r_{43}(1)$	-0,20263	-0,37323	-0,032030	Valid

Berdasarkan Tabel 4.32 dapat diketahui bahwa nilai parsial korelasi silang antar lokasi ada yang valid atau berbeda dengan nol (0), dan tidak valid. Parameter yang sama dengan tidak valid (0), yaitu lokasi ke-2, ke-3, dan ke-4 terhadap lokasi pertama sehingga bobot yang digunakan adalah bobot seragam. Hasil normalisasi inferensi korelasi silang parsial antar lokasi yang berbeda dengan nol adalah pada lokasi pertama terhadap lokasi kedua. Sedangkan untuk lokasi ke-3 dan ke-4 terhadap lokasi kedua nilai parsial korelasi silang antar lokasinya adalah tidak valid (0), sehingga bobot yang digunakan pada lokasi ini adalah bobot biner untuk lokasi yang valid terhadap lokasi kedua, dst. Sehingga metode bobot yang sesuai sebagai berikut

$$\mathbf{W} = \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ -1 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 \end{bmatrix}.$$

Hasil estimasi parameter GSTAR (1₁) residual data *inflow* dengan bobot NIKSP sebagai berikut

Tabel 4.33 Estimasi Parameter Bobot NIKSP Residual *Inflow*

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Surabaya	ϕ_{10}^1	1	0,203	0,088	2,30	0,0229
	ϕ_{11}^1	1	-0,689	0,345	2,00	0,0477
Malang	ϕ_{20}^1	1	0,343	0,078	4,39	<0,0001
	ϕ_{21}^1	1	0,084	0,030	2,78	0,0062
Kediri	ϕ_{30}^1	1	0,249	0,081	3,08	0,0026
	ϕ_{31}^1	1	0,065	0,028	2,33	0,0215
Jember	ϕ_{40}^1	1	-0,002	0,080	-0,02	0,9813
	ϕ_{41}^1	1	-0,052	0,052	-0,99	0,3224

Berdasarkan parameter model pada Tabel 4.33, dapat disajikan dalam bentuk persamaan matriks model GSTAR(1₁) sebagai berikut:

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,203 & 0 & 0 & 0 \\ 0 & 0,343 & 0 & 0 \\ 0 & 0 & 0,249 & 0 \\ 0 & 0 & 0 & -0,002 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} -0,689 & 0 & 0 & 0 \\ 0 & 0,084 & 0 & 0 \\ 0 & 0 & 0,065 & 0 \\ 0 & 0 & 0 & -0,052 \end{bmatrix} \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ -1 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Persamaan matriks model GSTAR(1₁) di atas, dapat disajikan dalam persamaan di masing-masing KPw BI sebagai berikut

Model GSTAR (1₁) di KPw BI Surabaya

$$N_t^{(1)} = 0,203N_{t-1}^{(1)} - 0,23N_{t-1}^{(2)} - 0,23N_{t-1}^{(3)} - 0,23N_{t-1}^{(4)} + a_t^{(1)}.$$

Model GSTAR (1₁) di KPw BI Malang

$$N_t^{(2)} = 0,343N_{t-1}^{(2)} - 0,084N_{t-1}^{(1)} + a_t^{(2)}.$$

Model GSTAR (1₁) di KPw BI Kediri

$$N_t^{(3)} = 0,249N_{t-1}^{(3)} - 0,065N_{t-1}^{(1)} + a_t^{(3)}.$$

Model GSTAR (1₁) di KPw BI Jember

$$N_t^{(4)} = -0,002N_{t-1}^{(4)} + 0,052N_{t-1}^{(3)} + a_t^{(4)}.$$

Kemudian dilakukan pengujian asumsi *white noise* yang disajikan pada Tabel 4.34.

Tabel 4.34 Nilai AIC Residual Model GSTAR Bobot NIKSP Data *Inflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	38,184	38,365	38,472	38,535	38,712	38,795
AR 1	38,231	38,436	38,607	38,709	38,915	39,043
AR 2	38,344	38,559	38,777	38,917	39,128	39,231
AR 3	38,445	38,611	38,805	39,021	39,269	39,463
AR 4	38,617	38,812	39,017	39,213	39,563	39,740
AR 5	38,751	39,006	39,253	39,452	39,588	39,948
AR 6	39,019	39,427	39,703	39,941	40,113	40,471


Berdasarkan Tabel 4.34, dapat diketahui bahwa nilai AIC terkecil terletak pada AR 0 dan MA 0 maka dapat dikatakan residual sudah memenuhi asumsi *white noise*.

Setelah dilakukan pemodelan menggunakan bobot seragam, bobot invers jarak, dan bobot normalisasi inferensi korelasi silang parsial, kemudian dihitung nilai kebaikan model berdasarkan ketiga bobot tersebut. Berikut adalah perbandingan nilai kebaikan model GSTARX dengan masing-masing bobot.


Tabel 4.35 Perbandingan Kebaikan Model GSTARX Masing-masing Bobot

Bobot	KPw BI	Kriteria Kebaikan Model			
		RMSE <i>In Sample</i>	RMSE <i>Out Sample</i>	MAPE <i>In Sample</i>	MAPE <i>Out Sample</i>
Seragam	Surabaya	461,5880	993,6996	39,5547	48,7390
	Malang	174,1077	493,7414	23,3846	26,2040
	Kediri	157,0387	427,1706	34,7803	30,1511
	Jember	97,1892	199,2929	21,6822	22,1611
Invers Jarak	Surabaya	459,3756	989,1893	39,2735	49,0792
	Malang	174,0925	493,7309	23,4015	26,2893
	Kediri	156,8735	427,8417	34,7407	30,2880
	Jember	97,1794	199,1600	21,6422	22,0606
NIKSP	Surabaya	465,2316	1018,0990	39,6834	50,1560
	Malang	176,2704	508,0606	23,4332	27,5499
	Kediri	158,5854	434,7702	34,7799	29,7105
	Jember	98,3879	205,1320	21,7012	23,2100

Berdasarkan Tabel 4.35 secara keseluruhan pemodelan residual *inflow* dengan bobot invers jarak memberikan nilai kesalahan ramalan terkecil berdasarkan kriteria RMSE. Sedangkan berdasarkan kriteria MAPE, pemodelan residual *inflow* dengan bobot seragam menghasilkan persentase kesalahan ramalan paling kecil. Berikut hasil ramalan *in sample* dan *out sample* pemodelan *inflow* menggunakan GSTARX bobot invers jarak di masing-masing KPw BI wilayah Jawa Timur.



Gambar 4.44 Perbandingan Data Aktual dan Ramalan Model GSTARX




Gambar 4.44 Perbandingan Data Aktual dan Ramalan Model GSTARX (lanjutan)

Berdasarkan Gambar 4.44, terlihat bahwa hasil ramalan *in sample* maupun *out sample* data *inflow* di masing-masing Kpw BI wilayah Jawa Timur sudah dapat menangkap pola variasi kalender, meskipun masih ada jarak yang relatif besar antara data ramalan dan data aktual.

III. Pemodelan *Inflow* Tahap Kedua Menggunakan *Hybrid* GSTAR-FFNN

Input yang digunakan pada pemodelan *hybrid* GSTAR-FFNN adalah variabel model GSTAR yang terdiri dari 8 variabel. Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* adalah 1, 2, 3, 4, 5, 10, dan 15. Fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang

terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Arsitektur pemodelan *hybrid* GSTAR-FFNN sebagai berikut



Gambar 4.45 Arsitektur Model *Hybrid* GSTAR-FFNN dengan 8 Variabel *Input*

dengan,

$$\mathbf{N}_{t-1}^{(1)*} = \begin{bmatrix} \mathbf{N}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-1}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(4)} \end{bmatrix}, \quad \hat{\mathbf{N}}_t = \begin{bmatrix} \hat{\mathbf{N}}_t^{(1)} \\ \hat{\mathbf{N}}_t^{(2)} \\ \hat{\mathbf{N}}_t^{(3)} \\ \hat{\mathbf{N}}_t^{(4)} \end{bmatrix},$$

$$\mathbf{W}_{t-1}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-1}^{(2)} + w_{13}\mathbf{N}_{t-1}^{(3)} + w_{14}\mathbf{N}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-1}^{(1)} + w_{23}\mathbf{N}_{t-1}^{(3)} + w_{24}\mathbf{N}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{W}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-1}^{(1)} + w_{32}\mathbf{N}_{t-1}^{(2)} + w_{34}\mathbf{N}_{t-1}^{(4)} \\ \mathbf{0} \end{bmatrix}, \quad \text{dan } \mathbf{W}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{41}\mathbf{N}_{t-1}^{(1)} + w_{42}\mathbf{N}_{t-1}^{(2)} + w_{43}\mathbf{N}_{t-1}^{(3)} \end{bmatrix}.$$

Tabel 4.35 menunjukkan hasil evaluasi model untuk data residual *inflow* menggunakan *hybrid* GSTARX-FFNN.

Tabel 4.36 Nilai Kebaikan Model *hybrid* GSTARX-FFNN Data *Inflow*

Bobot	Model	RMSE Out Sample			
		Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-FFNN (8,1,1)	1064,455	473,974	445,930	196,944
	GSTARX-FFNN (8,2,1)	1063,729	472,198	444,260	196,290
	GSTARX-FFNN (8,3,1)	1042,499	474,693	446,626	195,263
	GSTARX-FFNN (8,4,1)	1062,777	476,903	449,172	195,372
	GSTARX-FFNN (8,5,1)	1034,639	482,186	432,244	191,190
	GSTARX-FFNN (8,10,1)	1025,432	492,515	441,623	205,087
	GSTARX-FFNN (8,15,1)*	1068,463	443,579	423,480	176,953
Invers Jarak	GSTARX-FFNN (8,1,1)	1064,457	474,036	445,867	196,926
	GSTARX-FFNN (8,2,1)*	1012,201	457,174	417,874	189,555
	GSTARX-FFNN (8,3,1)	1051,945	476,100	440,818	206,923
	GSTARX-FFNN (8,4,1)	1060,619	477,578	450,470	194,800
	GSTARX-FFNN (8,5,1)	1033,045	482,274	432,586	192,037
	GSTARX-FFNN (8,10,1)	1023,275	492,434	440,147	204,053
	GSTARX-FFNN (8,15,1)	1062,645	444,242	423,596	180,854
NIKSP	GSTARX-FFNN (8,1,1)	1064,434	473,923	446,581	197,360
	GSTARX-FFNN (8,2,1)	1063,537	474,561	445,996	197,154
	GSTARX-FFNN (8,3,1)	1064,825	473,644	445,305	195,828
	GSTARX-FFNN (8,4,1)	1063,723	474,132	443,773	189,697
	GSTARX-FFNN (8,5,1)*	1042,723	467,863	435,097	184,984
	GSTARX-FFNN (8,10,1)	1040,256	479,470	433,634	198,087
	GSTARX-FFNN (8,15,1)	1081,018	457,167	410,335	215,965

*Model terbaik masing-masing bobot

Berdasarkan Tabel 4.36 model terbaik untuk masing-masing KPw BI berbeda-beda sehingga model terbaik ditentukan berdasarkan rata-rata RMSE terkecil di keempat KPw BI. Pemodelan *hybrid* GSTARX-FFNN dengan bobot seragam didapatkan model terbaik dengan jumlah *neuron* pada *hidden layer* sebanyak 15 unit atau dapat dituliskan sebagai GSTARX-FFNN(8,15,1). Menggunakan bobot invers jarak didapatkan model terbaik dengan jumlah *neuron* pada *hidden layer* sebanyak 2 unit atau dapat dituliskan sebagai GSTARX-FFNN(8,2,1). Sedangkan dengan bobot NIKSP model terbaik yang didapat adalah GSTARX-FFNN(8,5,1). Secara keseluruhan model *hybrid* GSTARX-FFNN (8,2,1) dengan bobot invers jarak merupakan model terbaik.

Arsitektur untuk model GSTAR-FFNN bobot invers jarak dengan 8 *input* dan 2 *neuron* pada *hidden layer* ditampilkan pada Gambar 4.46. Persamaan matematis untuk mendapatkan perhitungan manual sebagai berikut

$$\hat{Z}_t = \hat{Z}_t^{(1)} + \hat{N}_t^{(2)}, \quad (4.12)$$

dengan, $\hat{Z}_t^{(1)}$ pemodelan pada tahap pertama seperti pada persamaan (4.11) dan $\hat{N}_t^{(2)}$ merupakan pemodelan tahap kedua menggunakan *hybrid* GSTAR-FFNN dengan persamaan sebagai berikut (estimasi parameter pada Lampiran 42)

Persamaan pada *output layer*.


$$\hat{N}_t^* = 0,161 + 0,373f(x_1) + 0,068f(x_2).$$

dengan N_t^* = nilai *standardized* dari N_t .

Persamaan pada *hidden layer*


$$\begin{aligned} f(x_1) = & -0,377 + 0,49 \tanh(N_{t-1}^{(1)*}) - 0,215 \tanh(N_{t-1}^{(2)*}) - 0,141 \tanh(N_{t-1}^{(3)*}) - \\ & 0,115 \tanh(N_{t-1}^{(4)*}) - 0,614 \tanh(W_{t-1}^{(1)*}) + 0,124 \tanh(W_{t-1}^{(2)*}) - \\ & 0,158 \tanh(W_{t-1}^{(3)*}) + 0,048 \tanh(W_{t-1}^{(4)*}). \end{aligned}$$

$$\begin{aligned} f(x_2) = & -0,321 - 0,378 \tanh(N_{t-1}^{(1)*}) + 0,299 \tanh(N_{t-1}^{(2)*}) + 0,515 \tanh(N_{t-1}^{(3)*}) + \\ & 0,310 \tanh(N_{t-1}^{(4)*}) - 0,166 \tanh(W_{t-1}^{(1)*}) + 0,188 \tanh(W_{t-1}^{(2)*}) + \\ & 0,619 \tanh(W_{t-1}^{(3)*}) + 0,111 \tanh(W_{t-1}^{(4)*}). \end{aligned}$$



Gambar 4.46 Arsitektur GSTAR-FFNN(8,2,1) Bobot Invers Jarak

Berikut adalah *time series plot* data aktual dan ramalan dengan menggunakan model *hybrid* GSTARX-FFNN(8,2,1) bobot invers jarak.




Gambar 4.47 Perbandingan Data Aktual dan Ramalan Model GSTARX-FFNN

Berdasarkan Gambar 4.47 terlihat bahwa hasil ramalan menggunakan model GSTARX-FFNN sudah mampu menangkap pola variasi kalender meskipun masih ada jarak yang relatif lebar antara data ramalan dan data aktual.

IV. Pemodelan *Inflow* Tahap Kedua Menggunakan *Hybrid* GSTAR-DLNN

Pada pemodelan *hybrid* GSTAR-DLNN, *input* yang digunakan adalah variabel model GSTAR yang terdiri dari 8 variabel *input*. Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* pada *hidden layer* pertama adalah 1, 2, 3, 4, 5, 10, dan 15, sedangkan *hidden layer* kedua jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, 5. Fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Arsitektur pemodelan *hybrid* GSTAR-DLNN sebagai berikut



Gambar 4.48 Arsitektur Model *Hybrid* GSTAR-DLNN dengan 8 Variabel *Input*

dengan,

$$\mathbf{N}_{t-1}^{(1)*} = \begin{bmatrix} \mathbf{N}_{t-1}^{(1)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{N}_{t-1}^{(2)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(3)} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{N}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{t-1}^{(4)} \end{bmatrix}, \quad \hat{\mathbf{N}}_t = \begin{bmatrix} \hat{\mathbf{N}}_t^{(1)} \\ \hat{\mathbf{N}}_t^{(2)} \\ \hat{\mathbf{N}}_t^{(3)} \\ \hat{\mathbf{N}}_t^{(4)} \end{bmatrix},$$

$$\mathbf{W}_{t-1}^{(1)*} = \begin{bmatrix} w_{12}\mathbf{N}_{t-1}^{(2)} + w_{13}\mathbf{N}_{t-1}^{(3)} + w_{14}\mathbf{N}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad \mathbf{W}_{t-1}^{(2)*} = \begin{bmatrix} \mathbf{0} \\ w_{21}\mathbf{N}_{t-1}^{(1)} + w_{23}\mathbf{N}_{t-1}^{(3)} + w_{24}\mathbf{N}_{t-1}^{(4)} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix},$$

$$\mathbf{W}_{t-1}^{(3)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ w_{31}\mathbf{N}_{t-1}^{(1)} + w_{32}\mathbf{N}_{t-1}^{(2)} + w_{34}\mathbf{N}_{t-1}^{(4)} \\ \mathbf{0} \end{bmatrix}, \text{ dan } \mathbf{W}_{t-1}^{(4)*} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{41}\mathbf{N}_{t-1}^{(1)} + w_{42}\mathbf{N}_{t-1}^{(2)} + w_{43}\mathbf{N}_{t-1}^{(3)} \end{bmatrix}.$$

Hasil evaluasi model untuk data residual *inflow* menggunakan *hybrid* GSTARX-DLNN untuk masing-masing bobot disajikan pada Lampiran 43-45. Berikut adalah model terbaik masing-masing bobot dalam pemodelan *hybrid* GSTAR-DLNN.

Tabel 4.37 Nilai Kebaikan Model *hybrid* GSTARX-DLNN Data *Inflow*

Bobot	Model	RMSE In Sample				RMSE Out Sample			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-DLNN (8,10,4,1)	478,623	174,349	153,226	97,692	1047,469	464,225	436,855	198,192
Invers Jarak	GSTARX-DLNN (8,15,4,1)	469,467	172,467	157,712	102,492	1025,883	466,883	447,812	191,099
NIKSP	GSTARX-DLNN (8,15,2,1)	470,714	173,331	157,041	102,862	1024,987	473,623	437,273	202,429


Berdasarkan Tabel 4.37 model terbaik dengan menggunakan bobot seragam terdiri dari 10 unit *neuron* pada *hidden layer* pertama dan 4 unit *neuron* pada *hidden layer* kedua. Model terbaik dengan bobot NIKSP terdiri dari 15 unit *neuron* pada *hidden layer* pertama dan 2 unit *neuron* pada *hidden layer* kedua. Sedangkan dengan menggunakan bobot invers jarak terdiri dari 15 unit *neuron* pada *hidden layer* pertama dan 4 unit *neuron* pada *hidden layer* kedua. Diantara ketiga bobot, model *hybrid* GSTARX-DLNN(8,15,4,1) dengan bobot invers jarak memberikan kesalahan ramalan minimum berdasarkan kriteria RMSE *out sample*.

Arsitektur untuk model GSTAR-DLNN bobot seragam dengan 8 *input*, 15 unit *neuron* pada *hidden layer* pertama dan 4 unit *neuron* pada *hidden layer* kedua ditampilkan pada Gambar 4.49. Persamaan matematis untuk mendapatkan perhitungan manual seperti persamaan (4.12) dengan, $\hat{Z}_t^{(1)}$ pemodelan pada tahap pertama seperti pada persamaan (4.11) dan $\hat{N}_t^{(2)}$ merupakan pemodelan tahap kedua menggunakan *hybrid* GSTAR-DLNN(8,15,4,1) dengan persamaan sebagai berikut (estimasi parameter pada Lampiran 46)

Persamaan pada *output layer*.

$$\hat{\mathbf{N}}_t^* = 0,04 - 0,152f(x_{2,1}) - 0,081f(x_{2,2}) - 0,348f(x_{2,3}) - 0,107f(x_{2,4}).$$

dengan N_t^* = nilai *standardized* dari N_t .



Gambar 4.49 Arsitektur GSTAR-DLNN(8,15,4,1) Bobot Invers Jarak

Persamaan pada *hidden layer* kedua sebagai berikut

$$f(x_{2,1}) = -0,71 + 0,23 \tanh(f(x_{1,1})) - 0,176 \tanh(f(x_{1,2})) + 0,143 \tanh(f(x_{1,3})) + \\ 0,198 \tanh(f(x_{1,4})) - 0,445 \tanh(f(x_{1,5})) - 0,642 \tanh(f(x_{1,6})) - 0,183 \tanh(f(x_{1,7})) + \\ 0,393 \tanh(f(x_{1,8})) - 0,118 \tanh(f(x_{1,9})) + 0,305 \tanh(f(x_{1,10})) + 0,117 \tanh(f(x_{1,11})) + \\ 0,698 \tanh(f(x_{1,12})) - 0,24 \tanh(f(x_{1,13})) - 0,395 \tanh(f(x_{1,14})) - 0,543 \tanh(f(x_{1,15})).$$

$$f(x_{2,2}) = -0,181 + 0,491 \tanh(f(x_{1,1})) + 0,161 \tanh(f(x_{1,2})) - 0,285 \tanh(f(x_{1,3})) + \\ 0,362 \tanh(f(x_{1,4})) + 0,281 \tanh(f(x_{1,5})) + 0,072 \tanh(f(x_{1,6})) + 0,409 \tanh(f(x_{1,7})) - \\ 0,4 \tanh(f(x_{1,8})) - 0,415 \tanh(f(x_{1,9})) - 0,284 \tanh(f(x_{1,10})) - 0,526 \tanh(f(x_{1,11})) - \\ 0,679 \tanh(f(x_{1,12})) - 0,257 \tanh(f(x_{1,13})) - 0,584 \tanh(f(x_{1,14})) + 0,652 \tanh(f(x_{1,15})).$$

$$\begin{aligned}
f(x_{2,3}) = & -0,459 - 0,569 \tanh(f(x_{1,1})) - 0,607 \tanh(f(x_{1,2})) + 0,299 \tanh(f(x_{1,3})) + \\
& 0,793 \tanh(f(x_{1,4})) + 0,292 \tanh(f(x_{1,5})) - 0,342 \tanh(f(x_{1,6})) + \\
& 0,041 \tanh(f(x_{1,7})) + 0,016 \tanh(f(x_{1,8})) - 0,314 \tanh(f(x_{1,9})) - \\
& 0,519 \tanh(f(x_{1,10})) + 0,032 \tanh(f(x_{1,11})) + 0,087 \tanh(f(x_{1,12})) - \\
& 0,329 \tanh(f(x_{1,13})) + 0,305 \tanh(f(x_{1,14})) - 0,005 \tanh(f(x_{1,15})).
\end{aligned}$$

$$\begin{aligned}
f(x_{2,4}) = & 0,253 + 0,393 \tanh(f(x_{1,1})) + 0,321 \tanh(f(x_{1,2})) - 0,497 \tanh(f(x_{1,3})) + \\
& 0,131 \tanh(f(x_{1,4})) - 0,191 \tanh(f(x_{1,5})) - 0,44 \tanh(f(x_{1,6})) - \\
& 0,417 \tanh(f(x_{1,7})) + 0,016 \tanh(f(x_{1,8})) - 0,074 \tanh(f(x_{1,9})) - \\
& 0,376 \tanh(f(x_{1,10})) - 0,091 \tanh(f(x_{1,11})) + 0,159 \tanh(f(x_{1,12})) + \\
& 0,622 \tanh(f(x_{1,13})) - 0,051 \tanh(f(x_{1,14})) - 0,017 \tanh(f(x_{1,15})).
\end{aligned}$$

Persamaan pada *hidden layer* pertama sebagai berikut

$$\begin{aligned}
f(x_{1,1}) = & -0,49 - 0,295 \tanh(\mathbf{N}_{t-1}^{(1)*}) - 0,195 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,243 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,245 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
& 0,202 \tanh(\mathbf{W}_{t-1}^{(1)*}) + 0,163 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,109 \tanh(\mathbf{W}_{t-1}^{(3)*}) + 0,191 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,2}) = & -0,148 - 0,4 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,168 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,289 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,204 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
& 0,055 \tanh(\mathbf{W}_{t-1}^{(1)*}) + 0,138 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,184 \tanh(\mathbf{W}_{t-1}^{(3)*}) + 0,087 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,3}) = & -0,177 - 0,268 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,002 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,359 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,011 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
& 0,265 \tanh(\mathbf{W}_{t-1}^{(1)*}) + 0,281 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,174 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,14 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,4}) = & -0,109 - 0,044 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,238 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,334 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,474 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
& 0,136 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,268 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,553 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,068 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,5}) = & -0,165 + 0,388 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,056 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,456 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,277 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
& 0,254 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,284 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,161 \tanh(\mathbf{W}_{t-1}^{(3)*}) + 0,251 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,6}) = & -0,377 + 0,619 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,108 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,53 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,379 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
& 0,232 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,262 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,338 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,448 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,7}) = & -0,565 + 0,211 \tanh(\mathbf{N}_{t-1}^{(1)*}) - 0,043 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,24 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,346 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
& 0,231 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,27 \tanh(\mathbf{W}_{t-1}^{(2)*}) + 0,231 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,136 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,8}) = & 0,568 + 0,017 \tanh(\mathbf{N}_{t-1}^{(1)*}) - 0,335 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,457 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,192 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
& 0,35 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,459 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,458 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,415 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,9}) = & -0,021 + 0,793 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,43 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,354 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,215 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
& 0,324 \tanh(\mathbf{W}_{t-1}^{(1)*}) + 0,158 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,125 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,45 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$f(x_{1,10}) = -0,332 + 0,225 \tanh(N_{t-1}^{(1)*}) + 0,326 \tanh(N_{t-1}^{(2)*}) - 0,201 \tanh(N_{t-1}^{(3)*}) - 0,737 \tanh(N_{t-1}^{(4)*}) - 0,372 \tanh(W_{t-1}^{(1)*}) + 0,501 \tanh(W_{t-1}^{(2)*}) - 0,014 \tanh(W_{t-1}^{(3)*}) + 0,341 \tanh(W_{t-1}^{(4)*}).$$

$$f(x_{1,11}) = -0,075 - 0,123 \tanh(N_{t-1}^{(1)*}) - 0,167 \tanh(N_{t-1}^{(2)*}) - 0,358 \tanh(N_{t-1}^{(3)*}) + 0,041 \tanh(N_{t-1}^{(4)*}) + 0,369 \tanh(W_{t-1}^{(1)*}) - 0,258 \tanh(W_{t-1}^{(2)*}) + 0,305 \tanh(W_{t-1}^{(3)*}) + 0,171 \tanh(W_{t-1}^{(4)*}).$$


$$f(x_{1,12}) = 0,548 - 0,125 \tanh(N_{t-1}^{(1)*}) + 0,205 \tanh(N_{t-1}^{(2)*}) - 0,55 \tanh(N_{t-1}^{(3)*}) - 0,231 \tanh(N_{t-1}^{(4)*}) + 0,322 \tanh(W_{t-1}^{(1)*}) + 0,446 \tanh(W_{t-1}^{(2)*}) + 0,15 \tanh(W_{t-1}^{(3)*}) - 0,247 \tanh(W_{t-1}^{(4)*}).$$

$$f(x_{1,13}) = -0,499 - 0,38 \tanh(N_{t-1}^{(1)*}) + 0,128 \tanh(N_{t-1}^{(2)*}) + 0,292 \tanh(N_{t-1}^{(3)*}) - 0,321 \tanh(N_{t-1}^{(4)*}) - 0,423 \tanh(W_{t-1}^{(1)*}) - 0,54 \tanh(W_{t-1}^{(2)*}) + 0,335 \tanh(W_{t-1}^{(3)*}) + 0,369 \tanh(W_{t-1}^{(4)*}).$$


$$f(x_{1,14}) = -0,218 - 0,513 \tanh(N_{t-1}^{(1)*}) + 0,289 \tanh(N_{t-1}^{(2)*}) + 0,045 \tanh(N_{t-1}^{(3)*}) - 0,005 \tanh(N_{t-1}^{(4)*}) + 0,236 \tanh(W_{t-1}^{(1)*}) + 0,142 \tanh(W_{t-1}^{(2)*}) - 0,214 \tanh(W_{t-1}^{(3)*}) + 0,243 \tanh(W_{t-1}^{(4)*}).$$

$$f(x_{1,15}) = -0,322 + 0,067 \tanh(N_{t-1}^{(1)*}) - 0,302 \tanh(N_{t-1}^{(2)*}) + 0,028 \tanh(N_{t-1}^{(3)*}) + 0,222 \tanh(N_{t-1}^{(4)*}) - 0,437 \tanh(W_{t-1}^{(1)*}) - 0,086 \tanh(W_{t-1}^{(2)*}) - 0,123 \tanh(W_{t-1}^{(3)*}) - 0,13 \tanh(W_{t-1}^{(4)*}).$$

Berikut adalah *time series plot* data aktual dan ramalan dengan menggunakan model *hybrid* GSTARX-DLNN(8,15,4,1) bobot invers jarak.



Gambar 4.50 Perbandingan Data Aktual dan Ramalan Model GSTARX-DLNN



Gambar 4.50 Perbandingan Data Aktual dan Ramalan Model GSTARX-DLNN (lanjutan)

Berdasarkan Gambar 4.50 terlihat bahwa hasil ramalan menggunakan model GSTARX-DLNN sudah dapat menangkap pola variasi kalender tetapi di beberapa titik masih ada jarak yang relatif lebar antara data ramalan dan aktual.

4.2.4 Model Terbaik *Inflow* Uang Kartal di KPw BI Wilayah Jawa Timur

Setelah dilakukan pemodelan data *inflow* dengan VARX, GSTARX, dan *hybrid* GSTARX-ANN berikut ini ditampilkan perbandingan RMSE untuk masing-masing metode dan bobot lokasi yang digunakan.

Tabel 4.38 Kriteria Kebaikan Model Data *Inflow*

Model (Bobot)	RMSE Out Sample				
	Surabaya	Malang	Kediri	Jember	Rata-rata
VARX	1065,051	484,810	439,829	196,940	546,658
GSTARX (Seragam)	993,700	493,741	427,171	199,293	528,476
GSTARX (Invers Jarak)	989,189	493,731	427,842	199,160	527,481
GSTARX (NIKSP)	1018,099	508,061	434,770	205,132	541,516
GSTARX-FFNN (Seragam)	1068,463	443,579	423,480	176,953	528,119
GSTARX-FFNN (Invers Jarak)	1012,201	457,174	417,874	189,555	519,201
GSTARX-FFNN (NIKSP)	1042,723	467,863	435,097	184,984	532,667
GSTARX-DLNN (Seragam)	1047,469	464,225	436,855	198,192	536,685
GSTARX-DLNN (Invers Jarak)	1025,883	466,883	447,812	191,099	532,919
GSTARX-DLNN (NIKSP)	1024,987	473,623	437,273	202,429	534,578

Berdasarkan kriteria kebaikan model RMSE, pemodelan dengan menggunakan model GSTARX-FFNN bobot invers jarak menghasilkan kesalahan ramalan terkecil dibandingkan metode yang lainnya. Selanjutnya ditampilkan persentase penurunan nilai RMSE masing-masing model terhadap model GSTARX-FFNN bobot invers jarak berdasarkan rumus berikut


$$\text{Persentase Penurunan RMSE} = \frac{(\text{RMSE Model } i - \text{RMSE Model Terbaik})}{\text{RMSE Model } i} \times 100\%. \quad (4.13)$$

Tabel 4.39 Persentase Penurunan Nilai RMSE Terhadap Model *Hybrid* GSTARX-FFNN Bobot Invers Jarak


Model (Bobot)	Persentase Penurunan RMSE				
	Surabaya	Malang	Kediri	Jember	Rata-rata
VARX	4,96%	5,70%	4,99%	3,75%	5,02%
GSSTARX (Seragam)	-1,86%	7,41%	2,18%	4,89%	1,76%
GSSTARX (Invers Jarak)	-2,33%	7,40%	2,33%	4,82%	1,57%
GSSTARX (NIKSP)	0,58%	10,02%	3,89%	7,59%	4,12%
GSSTARX-DLNN (Seragam)	3,37%	1,52%	4,34%	4,36%	3,26%
GSSTARX-DLNN (Invers Jarak)	1,33%	2,08%	6,69%	0,81%	2,57%
GSSTARX-DLNN (NIKSP)	1,25%	3,47%	4,44%	6,36%	2,88%

Pada pemodelan data *inflow*, model *hybrid* GSTARX-FFNN mampu menurunkan kesalahan model VARX sebesar 5,02%, menurunkan kesalahan model GSTARX bobot seragam sebesar 1,76%, menurunkan kesalahan model GSTARX bobot invers jarak sebesar 1,57%, dan menurunkan kesalahan model GSTARX bobot NIKSP sebesar 4,12%.

Untuk mengetahui sampai *k-step* ke berapa model ini bisa memprediksi dengan baik data *inflow* di tiap lokasi dapat dilihat pada Gambar 4.51.



Gambar 4.51 Nilai RMSE *Out Sample k-Step Inflow* di KPw BI Jawa Timur



Gambar 4.51 Nilai RMSE *Out Sample k-Step Inflow* di KPw BI Jawa Timur (lanjutan)

Pemodelan data *inflow* menggunakan model *hybrid* GSTARX-FFNN (8,2,1) bobot invers jarak sudah cukup baik, hal ini ditunjukkan oleh Gambar 4.51 dimana nilai RMSE *in sample* di bawah nilai standar deviasi. Untuk mengetahui sampai berapa langkah ke depan model ini baik untuk meramalkan data *inflow* dilihat dari nilai RMSE *k-step*. Jika RMSE *k-step* berada di bawah standar deviasi maka ramalan *out sample* untuk *k-step* cukup baik. Namun jika berada di atas standar deviasi, berarti model tidak begitu baik dalam meramalkan data *out sample* sampai *k-step*.

Pada Gambar 4.51 dapat dilihat bahwa ramalan *out sample* pemodelan *hybrid* GSTARX-FFNN pada data *inflow* di KPw BI Surabaya dan Jember sudah cukup baik. Ramalan *out sample inflow* di KPw BI Surabaya dan Jember sampai tujuh langkah ke depan masih di bawah standar deviasi. Sedangkan ramalan *out sample inflow* di KPw BI Malang dan Kediri tidak begitu bagus di satu langkah kedepan. Pada *step* ke-1 nilai RMSE di KPw BI Malang dan Kediri cukup besar, hal ini mengindikasikan bahwa adanya pola musiman yang terjadi pada bulan Januari yang masih belum bisa dimodelkan dengan baik pada pemodelan *hybrid* GSTARX-FFNN.

Pada *step* ke-8 yaitu bulan Agustus, merupakan efek hari raya Idul Fitri yang terjadi pada minggu ke-4 bulan Juli, menyebabkan kenaikan nilai RMSE di masing-masing KPw BI wilayah Jawa Timur yang cukup tinggi sehingga melebihi nilai standar deviasi. Hal ini mengindikasikan bahwa ramalan model di masing-masing KPw BI wilayah Jawa Timur belum mampu menangkap pola variasi kalender dengan baik.

4.2.5 Pemodelan *Outflow* Tahap Pertama

Sama halnya dengan pemodelan *inflow*, pemodelan *outflow* tahap pertama yaitu pemodelan tren, musiman, dan variasi kalender dengan menggunakan *time series regression* dan metode estimasi yang digunakan adalah GLS. Berikut hasil estimasi parameter pemodelan tren, musiman, dan variasi kalender data *outflow* di masing-masing KPw BI wilayah Jawa Timur.

Tabel 4.40 Estimasi Parameter Tahap I *Outflow* di KPw BI Jawa Timur

KPw BI	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
Surabaya	D ₁	1	-1758,010	244,6179	-7,19	<0,0001
	D ₂	1	-3158,860	550,4088	-5,74	<0,0001
	tD ₁	1	15,972	3,1573	5,06	<0,0001
	tD ₂	1	33,858	4,8088	7,04	<0,0001
	S ₁	1	748,534	101,0768	7,41	<0,0001
	S ₂	1	833,215	100,9739	8,25	<0,0001
	S ₃	1	1084,942	155,0566	7,00	<0,0001
	S ₄	1	1246,289	155,0432	8,04	<0,0001
	S ₅	1	1154,756	155,0512	7,45	<0,0001
	S ₆	1	1415,242	155,0807	9,13	<0,0001
	S ₇	1	1426,792	156,1853	9,14	<0,0001
	S ₈	1	1283,990	163,4430	7,86	<0,0001
	S ₉	1	502,560	108,3977	4,64	<0,0001
	S ₁₀	1	564,443	108,5467	5,20	<0,0001
	S ₁₁	1	632,782	104,6251	6,05	<0,0001
	S ₁₂	1	1976,171	155,7059	12,69	<0,0001
	V _{2,t}	1	1555,260	257,4061	6,04	<0,0001
	V _{3,t}	1	2279,288	364,2730	6,26	<0,0001
	V _{4,t}	1	2381,265	295,6227	8,06	<0,0001
	V _{1,t-1}	1	2908,761	357,6580	8,13	<0,0001
	V _{2,t-1}	1	1625,149	257,5406	6,31	<0,0001
Malang	t	1	3,045	0,5788	5,26	<0,0001
	D ₁	1	-276,550	36,5023	-7,58	<0,0001
	D ₂	1	-173,673	53,9145	-3,22	0,0017
	S ₁	1	119,108	29,1889	4,08	<0,0001
	S ₂	1	126,597	29,4019	4,31	<0,0001
	S ₃	1	211,759	43,7533	4,84	<0,0001
	S ₄	1	253,862	43,9339	5,78	<0,0001
	S ₅	1	208,222	44,1215	4,72	<0,0001
	S ₆	1	345,567	44,3158	7,80	<0,0001
	S ₇	1	332,383	44,8988	7,40	<0,0001
	S ₈	1	277,147	46,8021	5,92	<0,0001

Tabel 4.40 Estimasi Parameter Tahap I *Outflow* di KPw BI Jawa Timur (lanjutan)

KPw BI	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
Malang	S ₉	1	201,651	32,6618	6,17	<0,0001
	S ₁₀	1	131,202	33,1352	3,96	0,0001
	S ₁₁	1	143,486	32,4812	4,42	<0,0001
	S ₁₂	1	552,291	45,6186	12,11	<0,0001
	V _{2,t}	1	302,691	69,0595	4,38	<0,0001
	V _{3,t}	1	827,793	97,8696	8,46	<0,0001
	V _{4,t}	1	705,742	79,2810	8,90	<0,0001
	V _{1,t-1}	1	803,558	96,0811	8,36	<0,0001
	V _{2,t-1}	1	444,567	69,1504	6,43	<0,0001
	V _{3,t-1}	1	129,729	57,9104	2,24	0,0271
Kediri	t	1	5,099	0,3634	14,03	<0,0001
	D ₁	1	-218,928	38,7869	-5,64	<0,0001
	S ₃	1	117,885	69,0866	1,71	0,0906
	S ₄	1	186,468	69,1813	2,70	0,0081
	S ₅	1	175,511	69,2778	2,53	0,0126
	S ₆	1	502,257	69,3762	7,24	<0,0001
	S ₇	1	409,611	69,7036	5,88	<0,0001
	S ₈	1	276,030	71,7923	3,84	0,0002
	S ₁₂	1	460,682	70,0027	6,58	<0,0001
	V _{2,t}	1	442,591	112,3187	3,94	0,0001
	V _{3,t}	1	1158,389	159,4542	7,26	<0,0001
	V _{4,t}	1	965,304	128,3457	7,52	<0,0001
	V _{1,t-1}	1	1282,092	154,9582	8,27	<0,0001
	V _{2,t-1}	1	684,987	112,5817	6,08	<0,0001
Jember	t	1	3,569	0,3809	9,37	<0,0001
	D ₁	1	-187,839	28,6886	-6,55	<0,0001
	D ₂	1	-669,787	121,8360	-5,50	<0,0001
	tD ₂	1	4,870	1,1165	4,36	<0,0001
	S ₃	1	111,063	33,4756	3,32	0,0012
	S ₄	1	118,275	33,5351	3,53	0,0006
	S ₅	1	84,294	33,5996	2,51	0,0135
	S ₆	1	238,614	33,6690	7,09	<0,0001
	S ₇	1	197,595	34,0151	5,81	<0,0001
	S ₈	1	179,763	34,9402	5,14	<0,0001
	S ₉	1	52,660	22,4734	2,34	0,0209
	S ₁₂	1	182,623	34,1862	5,34	<0,0001
	V _{2,t}	1	135,213	54,3428	2,49	0,0143
	V _{3,t}	1	389,061	77,4061	5,03	<0,0001
	V _{4,t}	1	457,015	62,1157	7,36	<0,0001

Tabel 4.40 Estimasi Parameter Tahap I *Outflow* di KPw BI Jawa Timur (lanjutan)

KPw BI	Variabel	DF	Estimasi Parameter	SE	t-value	P-value
Jember	$V_{1,t-1}$	1	594,452	75,3057	7,89	<0,0001
	$V_{2,t-1}$	1	304,513	54,5031	5,59	<0,0001
	$V_{4,t-1}$	1	94,618	38,8391	2,44	0,0164

Berdasarkan uji signifikansi parameter dapat diketahui bahwa *outflow* di KPw BI wilayah Jawa Timur dipengaruhi oleh tren, *dummy* kebijakan BI, musiman, dan variasi kalender. Berikut adalah model tahap I data *outflow* di masing-masing KPw BI Jawa Timur.

KPw BI Surabaya

$$\begin{aligned}
Z_t^{(1)} = & -1758,01D_{1,t} - 3158,86D_{2,t} + 15,972tD_{1,t} + 33,858tD_{2,t} + 748,534S_{1,t} + \\
& 833,215S_{2,t} + 1084,942S_{3,t} + 1246,289S_{4,t} + 1154,756S_{5,t} + 1415,242S_{6,t} + \\
& 1426,792S_{7,t} + 1283,99S_{8,t} + 502,560S_{9,t} + 564,443S_{10,t} + 632,782S_{11,t} + \\
& 1976,171S_{12,t} + 1555,26V_{2,t} + 2279,288V_{3,t} + 2381,265V_{4,t} + \\
& 2908,761V_{1,t-1} + 1625,149V_{2,t-1} + N_t^{(1)}.
\end{aligned} \quad (4.14)$$

KPw BI Malang

$$\begin{aligned}
Z_t^{(2)} = & 3,045t - 276,55D_{1,t} - 173,673D_{2,t} + 119,108S_{1,t} + 126,597S_{2,t} + \\
& 211,759S_{3,t} + 253,862S_{4,t} + 208,222S_{5,t} + 345,567S_{6,t} + \\
& 332,383S_{7,t} + 277,147S_{8,t} + 201,651S_{9,t} + 131,202S_{10,t} + \\
& 143,486S_{11,t} + 552,291S_{12,t} + 302,691V_{2,t} + 827,793V_{3,t} + \\
& 705,742V_{4,t} + 803,558V_{1,t-1} + 444,567V_{2,t-1} + 129,729V_{3,t-1} + N_t^{(2)}.
\end{aligned} \quad (4.15)$$

KPw BI Kediri

$$\begin{aligned}
Z_t^{(3)} = & 5,099t - 218,928D_{1,t} + 117,885S_{3,t} + 186,468S_{4,t} + 175,511S_{5,t} + \\
& 502,257S_{6,t} + 409,611S_{7,t} + 276,029S_{8,t} + 460,682S_{12,t} + 442,591V_{2,t} + \\
& 1158,389V_{3,t} + 965,304V_{4,t} + 1282,092V_{1,t-1} + 684,987V_{2,t-1} + N_t^{(3)}.
\end{aligned} \quad (4.16)$$

KPw BI Jember

$$\begin{aligned}
Z_t^{(4)} = & 3,569t - 187,839D_{1,t} - 669,787D_{2,t} + 4,87tD_{2,t} + 111,063S_{3,t} + \\
& 118,275S_{4,t} + 84,294S_{5,t} + 238,614S_{6,t} + 197,595S_{7,t} + 179,763S_{8,t} + \\
& 52,66S_{9,t} + 182,623S_{12,t} + 135,213V_{2,t} + 389,061V_{3,t} + 457,014V_{4,t} + \\
& 594,452V_{1,t-1} + 304,513V_{2,t-1} + 94,618V_{4,t-1} + N_t^{(4)}.
\end{aligned} \quad (4.17)$$

Berdasarkan persamaan (4.14)-(4.17) model tahap I data *outflow* di KPw BI Jawa Timur dapat disajikan dalam persamaan matriks sebagai berikut

$$\begin{aligned}
\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \\ Z_t^{(4)} \end{bmatrix} &= \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 3,04 & 0 & 0 \\ 0 & 0 & 5,099 & 0 \\ 0 & 0 & 0 & 3,569 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & -276,55 & 0 & 0 \\ 0 & 0 & -218,928 & 0 \\ 0 & 0 & 0 & -187,839 \end{bmatrix} \\
&+ \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots + \begin{bmatrix} 748,534 & 0 & 0 & 0 \\ 0 & 119,108 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \\ S_{1,t}^{(4)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 129,729 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \\ V_{3,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 94,618 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix}.
\end{aligned} \tag{4.18}$$


Selanjutnya dilakukan pemodelan tahap kedua yaitu memodelkan residual tahap pertama menggunakan VAR, GSTAR, dan *hybrid* GSTAR-ANN.

4.2.6 Pemodelan *Outflow* Tahap Kedua


Pemodelan *outflow* tahap kedua memodelkan residual tahap pertama menggunakan metode VAR, GSTAR, *hybrid* GSTAR-FFNN, dan *hybrid* GSTAR-DLNN. Berikut adalah pembahasan pemodelan *inflow* tahap kedua.

I. Pemodelan *Outflow* Tahap Kedua Menggunakan VAR

Pertama dilakukan identifikasi residual data *outflow* untuk mengetahui apakah data yang digunakan sudah stasioner. Proses identifikasi stasioneritas secara visual dengan melihat *time series plot* yang ditampilkan pada Gambar 4.52.



Gambar 4.52 *Time Series Plot* Residual Tahap I Data *Outflow* di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember



Gambar 4.52 Time Series Plot Residual Tahap I Data *Outflow* di KPw BI (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember (lanjutan)

Berdasarkan Gambar 4.52, *time series plot* residual dari ketiga lokasi diduga sudah stasioner karena berada disekitar $\mu=0$. Selain itu, identifikasi stasioneritas juga dapat dilihat berdasarkan skematik MCCF dan pemeriksaan orde waktu (Ar) melalui skematik MPCCF.

Schematic Representation of Cross Correlations													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	++++	-. -	.. +	++++
zresid2	++++	-. -	+.. +	++++
zresid3	++++ +	-. -	++++
zresid4	++++ +	-. -	+...

Gambar 4.53 Representasi Skema MCCF untuk Residual Data *Outflow*

Skema MCCF pada Gambar 4.53 menunjukkan bahwa data sudah stasioner, hal ini terlihat dari banyaknya tanda (.) yang muncul. Sedangkan skema MPCCF untuk residual *outflow* signifikan pada lag 1. Berdasarkan plot MPCCF tersebut, dapat diketahui bahwa orde dari model yang diduga adalah VAR(1).

Schematic Representation of Partial Cross Correlations												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	+...-
zresid2	-+..	-...-
zresid3	-..++	+...	+...
zresid4	..---	+..	+...

Gambar 4.54 Representasi Skematik MPCCF Residual Data *Outflow*

Selain melakukan pengecekan melalui plot MCCF dan MPCCF, perlu dilakukan pengecekan terhadap nilai AIC dari model.

Tabel 4.41 Nilai AIC Model VAR Residual Data *Outflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	38,084	38,243	38,331	38,487	38,638	38,791
AR 1	38,069	38,330	38,491	38,653	38,828	39,011
AR 2	38,229	38,544	38,655	38,812	38,921	39,105

Pada Tabel 4.41 menunjukkan bahwa nilai AIC terkecil dari model VAR adalah terletak di lag MA 0 dan AR 1. Model dugaan sama seperti skematik MPCCF yaitu VAR(1).

Pemodelan residual data *outflow* dengan model VAR(1) memiliki 16 parameter. Tetapi tidak semua parameter memiliki pengaruh yang signifikan terhadap model. Untuk mengatasi dilakukan *restrict* terhadap parameter tersebut. Perintah *restrict* dilakukan terhadap satu demi satu variabel yang tidak signifikan secara bertahap, sampai semua parameter signifikan. Sama seperti pemodelan pada residual data *inflow*, pada pemodelan residual data *outflow* setelah dilakukan *restrict* terdapat lokasi yang semua parameternya tidak signifikan, sehingga model yang digunakan adalah *full model* (melibatkan semua parameter tanpa memperhatikan signifikansinya) untuk keperluan meningkatkan akurasi ramalan. Berikut hasil estimasi parameter model VAR(1).

Tabel 4.42 Estimasi Parameter *Full Model* VAR(1) *Outflow*

KPw BI	Parameter	Estimasi	Standar Error	t-value	P-value	Variabel
Surabaya	ϕ_{11}^1	-0,274	0,170	-1,61	0,1089	$N_{t-1}^{(1)}$
	ϕ_{12}^1	-0,101	0,699	-0,14	0,8854	$N_{t-1}^{(2)}$
	ϕ_{13}^1	0,970	0,467	2,08	0,0396	$N_{t-1}^{(3)}$
	ϕ_{14}^1	-0,888	0,742	-1,20	0,2336	$N_{t-1}^{(4)}$
Malang	ϕ_{21}^1	-0,109	0,045	-2,41	0,0175	$N_{t-1}^{(1)}$
	ϕ_{22}^1	0,155	0,186	0,83	0,4079	$N_{t-1}^{(2)}$
	ϕ_{23}^1	0,208	0,124	1,67	0,0972	$N_{t-1}^{(3)}$
	ϕ_{24}^1	-0,110	0,198	-0,56	0,5791	$N_{t-1}^{(4)}$
Kediri	ϕ_{31}^1	-0,208	0,074	-2,82	0,0056	$N_{t-1}^{(1)}$
	ϕ_{32}^1	-0,008	0,305	-0,03	0,9793	$N_{t-1}^{(2)}$
	ϕ_{33}^1	0,382	0,203	1,88	0,0627	$N_{t-1}^{(3)}$
	ϕ_{34}^1	0,053	0,323	0,16	0,8708	$N_{t-1}^{(4)}$
Jember	ϕ_{41}^1	-0,090	0,035	-2,56	0,0116	$N_{t-1}^{(1)}$
	ϕ_{42}^1	-0,062	0,145	-0,43	0,6703	$N_{t-1}^{(2)}$
	ϕ_{43}^1	0,122	0,097	1,25	0,2125	$N_{t-1}^{(3)}$
	ϕ_{44}^1	0,324	0,154	2,10	0,0378	$N_{t-1}^{(4)}$

Berdasarkan Tabel 4.42 maka dapat dibentuk persamaan matematis model VARX(1) dalam bentuk matriks seperti berikut

Persamaan tahap I

$$\begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \\ Z_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 3,04 & 0 & 0 \\ 0 & 0 & 5,099 & 0 \\ 0 & 0 & 0 & 3,569 \end{bmatrix} \begin{bmatrix} t^{(1)} \\ t^{(2)} \\ t^{(3)} \\ t^{(4)} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & -276,55 & 0 & 0 \\ 0 & 0 & -218,928 & 0 \\ 0 & 0 & 0 & -187,839 \end{bmatrix} \begin{bmatrix} D_{1,t}^{(1)} \\ D_{1,t}^{(2)} \\ D_{1,t}^{(3)} \\ D_{1,t}^{(4)} \end{bmatrix} + \dots + \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 129,729 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} V_{3,t-1}^{(1)} \\ V_{3,t-1}^{(2)} \\ V_{3,t-1}^{(3)} \\ V_{3,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 94,62 \end{bmatrix} \begin{bmatrix} V_{4,t-1}^{(1)} \\ V_{4,t-1}^{(2)} \\ V_{4,t-1}^{(3)} \\ V_{4,t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix}.$$

Persamaan tahap II

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} -0,274 & -0,101 & 0,970 & -0,888 \\ -0,109 & 0,155 & 0,208 & -0,110 \\ -0,208 & -0,008 & 0,382 & 0,053 \\ -0,090 & -0,062 & 0,122 & 0,324 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Setelah melakukan estimasi parameter, langkah selanjutnya adalah melakukan pengujian asumsi *white noise*. Pengujian dilakukan dengan cara memodelkan ulang residual dari model. Jika letak AIC terkecil terdapat pada lag AR 0 dan MA 0, maka residual sudah memenuhi asumsi *white noise*.

Tabel 4.43 Nilai AIC Residual Model VAR Data *Outflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	37,822	38,196	38,331	38,522	38,701	38,800
AR 1	38,077	38,418	38,560	38,711	38,900	39,057
AR 2	38,240	38,551	38,672	38,848	38,907	39,025
AR 3	38,475	38,704	38,826	39,058	39,095	39,264
AR 4	38,631	38,792	38,944	39,127	39,383	39,634
AR 5	38,774	38,964	39,127	39,312	39,655	39,946
AR 6	38,986	39,394	39,604	39,828	40,231	40,589
AR 7	39,173	39,623	40,113	40,395	40,851	41,288
AR 8	39,384	39,881	40,426	41,026	41,553	42,067
AR 9	39,780	40,334	40,944	41,621	42,374	42,997
AR 10	40,139	40,759	41,448	42,217	43,080	44,057
AR 11	40,631	41,332	42,117	42,999	43,999	45,142
AR 12	40,977	41,778	42,680	43,704	44,878	46,235


Berdasarkan Tabel 4.43, dapat diketahui bahwa nilai AIC terkecil terletak pada AR 0 dan MA 0. Hal ini menunjukkan bahwa residual sudah memenuhi asumsi *white noise*.

Selanjutnya, untuk mengetahui kebaikan model VARX dalam meramalkan data *outflow*, dihitung nilai kebaikan model *in sample* maupun *out sample* yang disajikan pada Tabel 4.44.


Tabel 4.44 Nilai Kebaikan Model VARX(1) Data *Outflow*

Data	KPw BI	Kriteria Kebaikan Model	
		RMSE	MAPE
<i>In Sample</i>	Surabaya	455,331	52,426
	Malang	121,319	82,221
	Kediri	198,416	63,971
	Jember	94,715	63,873
<i>Out Sample</i>	Surabaya	961,901	56,402
	Malang	508,382	43,172
	Kediri	465,849	49,709
	Jember	292,195	72,541

Berdasarkan Tabel 4.44 menunjukkan bahwa nilai RMSE KPw BI yang rata-rata *outflow*-nya lebih besar akan cenderung semakin besar. Dengan demikian, perbandingan antar KPw BI sebaiknya dilakukan menggunakan kriteria yang berbasis persentase, misalnya MAPE. Nilai MAPE untuk masing-masing KPw BI wilayah Jawa Timur relatif besar. Selanjutnya dilakukan perbandingan data aktual dan ramalan untuk setiap KPw BI ditunjukkan pada gambar 4.55.



Gambar 4.55 Perbandingan Data *Outflow* Aktual dan Ramalan Model VARX



Gambar 4.55 Perbandingan Data *Outflow* Aktual dan Ramalan Model VARX (lanjutan)

Terlihat pada Gambar 4.55 bahwa hasil ramalan data *outflow* VARX di masing-masing KPw BI wilayah Jawa Timur sudah dapat menangkap pola variasi kalender, tetapi masih ada jarak yang cukup lebar antara ramalan dan data aktual.

II. Pemodelan *Outflow* Tahap Kedua Menggunakan GSTAR

Orde model yang digunakan dalam pemodelan GSTAR sama dengan orde VAR, yaitu $\text{GSTAR}(1_1)$. Estimasi parameter yang digunakan dalam pemodelan adalah GLS. Model yang digunakan adalah *full model* yaitu semua parameter digunakan tanpa memperhatikan signifikansinya dikarenakan pemodelan dengan *restrict* terdapat lokasi yang semua parameternya tidak signifikan. Bobot lokasi yang digunakan dalam pemodelan GSTAR yaitu bobot seragam, invers jarak, dan NIKSP dengan pembahasan sebagai berikut:

a. Bobot Seragam

Penerapan bobot seragam pada pemodelan GSTAR mengasumsikan bahwa masing-masing data *outflow* di KPw BI wilayah Jawa Timur memiliki keterkaitan yang sama sehingga pemberian bobot untuk lokasi ke- i dan j adalah sama. Matriks bobot seragam yang digunakan sebagai berikut

$$\mathbf{W} = \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix}.$$

Berikut adalah hasil estimasi parameter GSTAR (1₁) residual data *outflow*.

Tabel 4.45 Estimasi Parameter Bobot Seragam Residual *Outflow*

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Surabaya	ϕ_{10}^1	1	0,0392	0,103	0,38	0,7038
	ϕ_{11}^1	1	-0,3293	0,354	-0,93	0,3543
Malang	ϕ_{20}^1	1	0,1534	0,105	1,46	0,1474
	ϕ_{21}^1	1	-0,0770	0,060	-1,28	0,2032
Kediri	ϕ_{30}^1	1	0,1011	0,089	1,13	0,2593
	ϕ_{31}^1	1	-0,1731	0,100	-1,73	0,0860
Jember	ϕ_{40}^1	1	0,3348	0,078	4,30	<0,0001
	ϕ_{41}^1	1	-0,1007	0,040	-2,51	0,0134

Berdasarkan parameter model pada Tabel 4.45, maka dapat dibentuk persamaan model GSTAR(1₁) untuk residual *outflow* dalam bentuk persamaan matriks sebagai berikut

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,039 & 0 & 0 & 0 \\ 0 & 0,153 & 0 & 0 \\ 0 & 0 & 0,101 & 0 \\ 0 & 0 & 0 & 0,335 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} -0,329 & 0 & 0 & 0 \\ 0 & -0,077 & 0 & 0 \\ 0 & 0 & -0,173 & 0 \\ 0 & 0 & 0 & -0,101 \end{bmatrix} \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Persamaan matriks model GSTAR(1₁) di atas, dapat disajikan dalam persamaan di masing-masing KPw BI sebagai berikut

Model GSTAR (1₁) di KPw BI Surabaya

$$N_t^{(1)} = 0,039N_{t-1}^{(1)} - 0,109N_{t-1}^{(2)} - 0,109N_{t-1}^{(3)} - 0,109N_{t-1}^{(4)} + a_t^{(1)}.$$

Model GSTAR (1₁) di KPw BI Malang

$$N_t^{(2)} = 0,153N_{t-1}^{(2)} - 0,026N_{t-1}^{(1)} - 0,026N_{t-1}^{(3)} - 0,026N_{t-1}^{(4)} + a_t^{(2)}.$$

Model GSTAR (1₁) di KPw BI Kediri

$$N_t^{(3)} = 0,101N_{t-1}^{(3)} - 0,058N_{t-1}^{(1)} - 0,058N_{t-1}^{(2)} - 0,058N_{t-1}^{(4)} + a_t^{(3)}.$$

Model GSTAR (1₁) di KPw BI Jember

$$N_t^{(4)} = 0,335N_{t-1}^{(4)} + 0,034N_{t-1}^{(1)} + 0,034N_{t-1}^{(2)} + 0,034N_{t-1}^{(3)} + a_t^{(4)}.$$

Kemudian dilakukan pengujian asumsi *white noise* dengan cara memodelkan ulang residual dari model, jika letak AIC terkecil terdapat pada lag AR 0 dan MA 0, maka residual dapat dikatakan sudah memenuhi asumsi *white noise*.

Tabel 4.46 Nilai AIC Residual Model GSTAR Bobot Seragam Data *Outflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	37,918	38,184	38,320	38,492	38,668	38,786
AR 1	38,058	38,364	38,520	38,655	38,849	39,018
AR 2	38,237	38,524	38,741	38,858	38,949	39,062
AR 3	38,461	38,691	38,784	39,033	39,162	39,346
AR 4	38,619	38,809	38,959	39,194	39,430	39,660
AR 5	38,780	38,977	39,130	39,294	39,640	39,940
AR 6	38,997	39,405	39,607	39,813	40,215	40,585

Berdasarkan Tabel 4.46, dapat diketahui bahwa nilai AIC terkecil terletak pada AR 0 dan MA 0 sehingga residual sudah memenuhi asumsi *white noise*.

b. Bobot Invers Jarak

Pemodelan GSTAR(1₁) dengan menggunakan bobot invers jarak mengasumsikan bahwa data *outflow* di masing-masing KPw BI wilayah Jawa Timur dipengaruhi oleh jarak antar lokasi KPw BI Jawa Timur. Matriks bobot invers jarak yang digunakan sebagai berikut

$$\mathbf{W} = \begin{bmatrix} 0 & 0,45 & 0,33 & 0,22 \\ 0,40 & 0 & 0,39 & 0,21 \\ 0,35 & 0,47 & 0 & 0,18 \\ 0,35 & 0,38 & 0,27 & 0 \end{bmatrix}.$$

Hasil estimasi parameter GSTAR (1₁) residual data *outflow* dengan bobot invers jarak sebagai berikut

Tabel 4.47 Estimasi Parameter Bobot Inversss Jarak Residual *Outflow*

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Surabaya	ϕ_{10}^1	1	0,0203	0,106	0,19	0,8476
	ϕ_{11}^1	1	-0,2618	0,355	-0,74	0,4624
Malang	ϕ_{20}^1	1	0,1474	0,106	1,39	0,1655
	ϕ_{21}^1	1	-0,0671	0,053	-1,27	0,2057

Tabel 4.47 Estimasi Parameter Bobot Invers Jarak Residual *Outflow* (lanjutan)

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Kediri	ϕ_{30}^1	1	0,1152	0,087	1,33	0,1865
	ϕ_{31}^1	1	-0,1814	0,095	-1,91	0,0581
Jember	ϕ_{40}^1	1	0,3428	0,077	4,46	<0,0001
	ϕ_{41}^1	1	-0,1044	0,040	-2,59	0,0108

Berdasarkan parameter model pada Tabel 4.47, maka dapat dibentuk persamaan model GSTAR(1₁) untuk residual *outflow* dalam bentuk persamaan matriks sebagai berikut

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} 0,02 & 0 & 0 & 0 \\ 0 & 0,147 & 0 & 0 \\ 0 & 0 & 0,115 & 0 \\ 0 & 0 & 0 & 0,343 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} -0,262 & 0 & 0 & 0 \\ 0 & -0,067 & 0 & 0 \\ 0 & 0 & -0,181 & 0 \\ 0 & 0 & 0 & -0,104 \end{bmatrix} \begin{bmatrix} 0 & 0,45 & 0,33 & 0,22 \\ 0,40 & 0 & 0,39 & 0,21 \\ 0,35 & 0,47 & 0 & 0,18 \\ 0,35 & 0,38 & 0,27 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Persamaan matriks model GSTAR(1₁) di atas, dapat disajikan dalam persamaan di masing-masing KPw BI sebagai berikut

Model GSTAR (1₁) di KPw BI Surabaya

$$N_t^{(1)} = 0,02N_{t-1}^{(1)} - 0,118N_{t-1}^{(2)} - 0,086N_{t-1}^{(3)} - 0,058N_{t-1}^{(4)} + a_t^{(1)}.$$

Model GSTAR (1₁) di KPw BI Malang

$$N_t^{(2)} = 0,147N_{t-1}^{(2)} - 0,027N_{t-1}^{(1)} - 0,026N_{t-1}^{(3)} - 0,014N_{t-1}^{(4)} + a_t^{(2)}.$$

Model GSTAR (1₁) di KPw BI Kediri

$$N_t^{(3)} = 0,115N_{t-1}^{(3)} - 0,063N_{t-1}^{(1)} - 0,085N_{t-1}^{(2)} - 0,033N_{t-1}^{(4)} + a_t^{(3)}.$$

Model GSTAR (1₁) di KPw BI Jember

$$N_t^{(4)} = 0,343N_{t-1}^{(4)} + 0,036N_{t-1}^{(1)} + 0,039N_{t-1}^{(2)} + 0,028N_{t-1}^{(3)} + a_t^{(4)}.$$

Kemudian dilakukan pengujian asumsi *white noise* dengan cara memodelkan ulang residual dari model, jika letak AIC terkecil terdapat pada lag AR 0 dan MA 0, maka residual sudah memenuhi asumsi *white noise*.

Tabel 4.48 Nilai AIC Residual Model GSTAR Bobot Invers Jarak Data *Outflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	37,916	38,181	38,319	38,491	38,668	38,786
AR 1	38,058	38,366	38,522	38,660	38,854	39,022
AR 2	38,238	38,525	38,742	38,857	38,942	39,059
AR 3	38,462	38,692	38,783	39,028	39,161	39,360

Terlihat pada Tabel 4.48 nilai AIC terkecil terletak pada AR 0 dan MA 0 sehingga residual sudah memenuhi asumsi *white noise*.

c. Bobot Normalisasi Inferensi Korelasi Silang Parsial

Pemodelan GSTAR(1₁) dengan menggunakan bobot normalisasi inferensi korelasi silang parsial (NIKSP) dilakukan dengan melihat nilai tinggi rendahnya korelasi silang parsial antar lokasi pada data.

Variable/ Lag	Schematic Representation of Partial Cross Correlations											
	1	2	3	4	5	6	7	8	9	10	11	12
zresid1	..-.	-...-.	+...	...+
zresid2
zresid3	+...	+...
zresid4	...+

Gambar 4.56 Sekmatik Korelasi Silang Parsial antar Lokasi Residual *Outflow*

Hasil perhitungan korelasi silang parsial antar lokasi pada lag 1, $r_{ij} = 1$ dengan $i, j = 1, 2, 3, 4$ dan $i \neq j$ dapat dilihat pada Tabel 4.49. Taksiran interval yang digunakan untuk perhitungan batas bawah dan batas atas parsial silang korelasi adalah 95%.

Tabel 4.49 Taksiran Normalisasi Inferensi Korelasi Silang Parsial antar Lokasi

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$r_{12}(1)$	-0,01873	-0,18933	0,15187	Tidak Valid
$r_{13}(1)$	-0,23129	-0,40189	-0,06069	Valid
$r_{14}(1)$	0,01025	-0,16035	0,18085	Tidak Valid
$r_{21}(1)$	-0,03069	-0,20129	0,13991	Tidak Valid
$r_{23}(1)$	-0,01002	-0,18062	0,16058	Tidak Valid
$r_{24}(1)$	-0,00581	-0,17641	0,16479	Tidak Valid
$r_{31}(1)$	0,10724	-0,06336	0,27784	Tidak Valid
$r_{32}(1)$	0,06629	-0,10431	0,23689	Tidak Valid
$r_{34}(1)$	0,11692	-0,05368	0,28752	Tidak Valid
$r_{41}(1)$	-0,14850	-0,31910	0,02210	Tidak Valid
$r_{42}(1)$	-0,00560	-0,17620	0,16500	Tidak Valid
$r_{43}(1)$	0,07093	-0,09967	0,24153	Tidak Valid

Berdasarkan Tabel 4.49 dapat diketahui bahwa nilai parsial korelasi silang antar lokasi ada yang valid atau berbeda dengan nol (0), dan tidak valid. Parameter yang sama dengan tidak valid (0), yaitu lokasi ke-1, ke-3, dan ke-4 terhadap lokasi kedua sehingga bobot yang digunakan adalah bobot seragam.

Hasil normalisasi inferensi korelasi silang parsial antar lokasi yang berbeda dengan nol adalah pada lokasi ketiga terhadap lokasi pertama. Sedangkan untuk lokasi ke-2 dan ke-4 terhadap lokasi pertama nilai parsial korelasi silang antar lokasinya adalah tidak valid (0), sehingga bobot yang digunakan pada lokasi ini adalah bobot biner untuk lokasi yang valid terhadap lokasi kedua, dan seterusnya. Sehingga metode bobot yang sesuai sebagai berikut

$$\mathbf{W} = \begin{bmatrix} 0 & 0 & -1 & 0 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix}.$$

Hasil estimasi parameter GSTAR (1₁) residual data *outflow* dengan bobot NIKSP sebagai berikut

Tabel 4.50 Estimasi Parameter Bobot NIKSP Residual *Outflow*

KPw BI	Parameter	DF	Estimasi Parameter	SE	t-Value	P-value
Surabaya	ϕ_{10}^1	1	-0,01057	0,099	-0,11	0,9153
	ϕ_{11}^1	1	0,02683	0,212	0,13	0,8995
Malang	ϕ_{20}^1	1	0,17004	0,105	1,62	0,1079
	ϕ_{21}^1	1	-0,07218	0,061	-1,18	0,2383
Kediri	ϕ_{30}^1	1	0,12009	0,091	1,32	0,1880
	ϕ_{31}^1	1	-0,16682	0,099	-1,67	0,0976
Jember	ϕ_{40}^1	1	0,34337	0,078	4,41	<0,0001
	ϕ_{41}^1	1	-0,09480	0,040	-2,36	0,0198

Berdasarkan parameter model pada Tabel 4.50, dapat disajikan dalam bentuk persamaan matriks model GSTAR(1₁) sebagai berikut:

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \\ N_t^{(4)} \end{bmatrix} = \begin{bmatrix} -0,011 & 0 & 0 & 0 \\ 0 & 0,17 & 0 & 0 \\ 0 & 0 & 0,12 & 0 \\ 0 & 0 & 0 & 0,343 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} +$$

$$\begin{bmatrix} 0,027 & 0 & 0 & 0 \\ 0 & -0,072 & 0 & 0 \\ 0 & 0 & -0,167 & 0 \\ 0 & 0 & 0 & -0,094 \end{bmatrix} \begin{bmatrix} 0 & 0 & -1 & 0 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \\ N_{t-1}^{(4)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \\ a_t^{(4)} \end{bmatrix}.$$

Persamaan matriks model GSTAR(1₁) di atas, dapat disajikan dalam persamaan di masing-masing KPw BI sebagai berikut

Model GSTAR (1₁) di KPw BI Surabaya

$$N_t^{(1)} = -0,011N_{t-1}^{(1)} - 0,027N_{t-1}^{(3)} + a_t^{(1)}.$$

Model GSTAR (1₁) di KPw BI Malang

$$N_t^{(2)} = 0,17N_{t-1}^{(2)} - 0,024N_{t-1}^{(1)} - 0,024N_{t-1}^{(3)} - 0,024N_{t-1}^{(4)} + a_t^{(2)}.$$

Model GSTAR (1₁) di KPw BI Kediri

$$N_t^{(3)} = 0,12N_{t-1}^{(3)} - 0,056N_{t-1}^{(1)} - 0,056N_{t-1}^{(2)} - 0,056N_{t-1}^{(4)} + a_t^{(3)}.$$

Model GSTAR (1₁) di KPw BI Jember

$$N_t^{(4)} = 0,343N_{t-1}^{(4)} - 0,032N_{t-1}^{(1)} - 0,032N_{t-1}^{(2)} - 0,032N_{t-1}^{(3)} + a_t^{(4)}.$$

Kemudian dilakukan pengujian asumsi *white noise* sebagai berikut

Tabel 4.51 Nilai AIC Residual Model GSTAR Bobot NIKSP Data *Outflow*

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	37,919	38,177	38,315	38,485	38,662	38,782
AR 1	38,057	38,367	38,519	38,663	38,856	39,016
AR 2	38,239	38,524	38,753	38,865	38,954	39,074
AR 3	38,462	38,688	38,783	39,019	39,163	39,368
AR 4	38,619	38,810	38,962	39,173	39,413	39,646
AR 5	38,782	38,972	39,133	39,292	39,638	39,937
AR 6	38,992	39,400	39,610	39,811	40,213	40,583
AR 7	39,177	39,626	40,116	40,374	40,832	41,278


Berdasarkan Tabel 4.51, dapat diketahui bahwa nilai AIC terkecil terletak pada AR 0 dan MA 0 maka dapat dikatakan residual sudah memenuhi asumsi *white noise*.

Setelah dilakukan pemodelan residual *outflow* menggunakan bobot seragam, bobot invers jarak, dan bobot normalisasi inferensi korelasi silang parsial, kemudian dihitung nilai kebaikan model berdasarkan ketiga bobot tersebut. Berikut adalah perbandingan nilai kebaikan model GSTARX dengan masing-masing bobot.


Tabel 4.52 Perbandingan Kebaikan Model GSTARX Masing-masing Bobot

Bobot	KPw BI	Kriteria Kebaikan Model			
		RMSE <i>In Sample</i>	RMSE <i>Out Sample</i>	MAPE <i>In Sample</i>	MAPE <i>Out Sample</i>
Seragam	Surabaya	467,061	879,836	55,421	51,185
	Malang	123,807	516,891	88,765	49,863
	Kediri	202,607	424,108	70,270	44,017
	Jember	96,277	291,600	62,387	66,524
Invers Jarak	Surabaya	466,340	884,596	55,169	51,513
	Malang	123,769	516,756	88,583	49,514
	Kediri	202,201	420,238	70,086	42,992
	Jember	96,126	290,927	62,598	66,381
NIKSP	Surabaya	465,013	945,910	54,761	55,354
	Malang	123,817	521,353	89,325	51,061
	Kediri	202,432	429,719	70,238	45,292
	Jember	96,2754	293,610	61,935	66,534

Berdasarkan Tabel 4.52 secara keseluruhan pemodelan residual *outflow* dengan bobot invers jarak memberikan nilai kesalahan ramalan terkecil berdasarkan kriteria RMSE dan MAPE. Berikut hasil ramalan *in sample* dan *out sample* pemodelan *outflow* menggunakan GSTARX bobot invers jarak di masing-masing KPw BI wilayah Jawa Timur.



Gambar 4.57 Perbandingan Data *Outflow* Aktual dan Ramalan Model GSTARX



Gambar 4.57 Perbandingan Data *Outflow* Aktual dan Ramalan Model GSTARX (lanjutan)

Berdasarkan Gambar 4.57, terlihat bahwa hasil ramalan *in sample* maupun *out sample* data *outflow* di masing-masing Kpw BI wilayah Jawa Timur sudah dapat menangkap pola variasi kalender, tetapi masih ada jarak yang relatif besar antara data ramalan dan data aktual.

III. Pemodelan *Outflow* Tahap Kedua Menggunakan *Hybrid* GSTAR-FFNN

Pada pemodelan *outflow* tahap kedua menggunakan *hybrid* GSTAR-FFNN, *input* yang digunakan adalah semua variabel model GSTAR yang terdiri dari 8 variabel *input*. Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* adalah 1, 2, 3, 4, 5, 10, dan 15. Fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Arsitektur pemodelan tahap kedua menggunakan *hybrid* GSTAR-FFNN seperti pada Gambar 4.45. Berikut adalah hasil evaluasi model untuk data residual *outflow* menggunakan *hybrid* GSTARX-FFNN.

Tabel 4.53 Nilai Keباikan Model *hybrid* GSTARX-FFNN Data *Outflow*

Bobot	Model	RMSE out Sample			
		Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-FFNN (8,1,1)	965,623	508,056	460,396	301,116
	GSTARX-FFNN (8,2,1)	965,729	505,569	464,652	287,179
	GSTARX-FFNN (8,3,1)	956,323	503,900	457,863	300,812
	GSTARX-FFNN (8,4,1)	955,782	503,497	457,156	300,695
	GSTARX-FFNN (8,5,1)*	966,487	510,740	434,344	292,193
	GSTARX-FFNN (8,10,1)	1012,706	541,744	409,532	311,616
	GSTARX-FFNN (8,15,1)	946,216	507,494	450,678	288,284
Invers Jarak	GSTARX-FFNN (8,1,1)	962,418	502,210	461,073	301,776
	GSTARX-FFNN (8,2,1)	960,198	507,588	466,640	296,414
	GSTARX-FFNN (8,3,1)	968,129	500,317	465,621	294,467
	GSTARX-FFNN (8,4,1)	965,661	499,096	462,085	297,344
	GSTARX-FFNN (8,5,1)	947,204	502,392	443,508	286,592
	GSTARX-FFNN (8,10,1)	972,525	509,009	455,001	298,548
	GSTARX-FFNN (8,15,1)*	1008,180	507,027	399,580	284,916
NIKSP	GSTARX-FFNN (8,1,1)	953,840	511,275	456,274	299,074
	GSTARX-FFNN (8,2,1)	961,562	498,442	457,539	300,933
	GSTARX-FFNN (8,3,1)*	958,290	502,646	460,931	294,794
	GSTARX-FFNN (8,4,1)	961,125	512,883	459,246	299,703
	GSTARX-FFNN (8,5,1)	971,152	502,726	437,796	306,718
	GSTARX-FFNN (8,10,1)	948,600	518,828	472,408	292,314
	GSTARX-FFNN (8,15,1)	989,985	514,473	452,552	299,055

Ket: *model terbaik

Berdasarkan Tabel 4.53 model terbaik untuk masing-masing KPw BI berbeda-beda sehingga model terbaik ditentukan berdasarkan rata-rata RMSE terkecil di keempat KPw BI. Pemodelan *hybrid* GSTARX-FFNN dengan bobot invers jarak didapatkan model terbaik dengan jumlah *neuron* pada *hidden layer* sebanyak 15 unit atau dapat dituliskan sebagai GSTARX-FFNN(8,15,1). Pemodelan *hybrid* GSTARX-FFNN dengan bobot seragam didapatkan model terbaik yaitu GSTARX-FFNN(8,5,1). Sedangkan dengan bobot NIKSP model terbaik adalah GSTARX-FFNN(8,3,1). Secara keseluruhan model *hybrid* GSTARX-FFNN(8,15,1) dengan bobot invers jarak memberikan rata-rata RMSE terkecil di empat lokasi KPw BI.

Arsitektur untuk model GSTAR-FFNN bobot invers jarak dengan 8 *input* dan 15 *neuron* pada *hidden layer* ditampilkan pada Gambar 4.58. Persamaan matematis untuk mendapatkan perhitungan manual seperti persamaan (4.12)

dengan, $\hat{Z}_t^{(1)}$ pemodelan pada tahap pertama seperti pada persamaan (4.18) dan $\hat{N}_t^{(2)}$ merupakan pemodelan tahap kedua menggunakan *hybrid* GSTAR-FFNN dengan persamaan sebagai berikut (estimasi parameter pada Lampiran 48)

Persamaan pada *output layer* sebagai berikut


$$\begin{aligned}\hat{N}_t^* = & -0,312 - 0,132f(x_1) + 0,171f(x_2) + 0,262f(x_3) - 0,146f(x_4) + 0,005f(x_5) - \\ & 0,051f(x_6) - 0,402f(x_7) + 0,137f(x_8) - 0,041f(x_9) + 0,135f(x_{10}) + \\ & 0,05f(x_{11}) + 0,378f(x_{12}) + 0,036f(x_{13}) + 0,074f(x_{14}) + 0,22f(x_{15}).\end{aligned}$$

dengan N_t^* = nilai *standardized* dari N_t .

Persamaan pada *hidden layer* sebagai berikut


$$\begin{aligned}f(x_1) = & -0,075 + 0,102 \tanh(N_{t-1}^{(1)*}) - 0,17 \tanh(N_{t-1}^{(2)*}) - 0,395 \tanh(N_{t-1}^{(3)*}) + 0,059 \tanh(N_{t-1}^{(4)*}) + \\ & 0,267 \tanh(W_{t-1}^{(1)*}) + 0,388 \tanh(W_{t-1}^{(2)*}) + 0,405 \tanh(W_{t-1}^{(3)*}) + 0,432 \tanh(W_{t-1}^{(4)*}). \\ f(x_2) = & -0,264 + 0,37 \tanh(N_{t-1}^{(1)*}) - 0,351 \tanh(N_{t-1}^{(2)*}) - 0,357 \tanh(N_{t-1}^{(3)*}) - 0,378 \tanh(N_{t-1}^{(4)*}) + \\ & 0,178 \tanh(W_{t-1}^{(1)*}) + 0,268 \tanh(W_{t-1}^{(2)*}) - 0,094 \tanh(W_{t-1}^{(3)*}) + 0,055 \tanh(W_{t-1}^{(4)*}). \\ f(x_3) = & 0,487 + 0,101 \tanh(N_{t-1}^{(1)*}) - 0,261 \tanh(N_{t-1}^{(2)*}) - 0,225 \tanh(N_{t-1}^{(3)*}) - 0,304 \tanh(N_{t-1}^{(4)*}) + \\ & 0,316 \tanh(W_{t-1}^{(1)*}) - 0,12 \tanh(W_{t-1}^{(2)*}) - 0,054 \tanh(W_{t-1}^{(3)*}) - 0,289 \tanh(W_{t-1}^{(4)*}). \\ f(x_4) = & 0,018 - 0,371 \tanh(N_{t-1}^{(1)*}) - 0,233 \tanh(N_{t-1}^{(2)*}) - 0,225 \tanh(N_{t-1}^{(3)*}) - 0,192 \tanh(N_{t-1}^{(4)*}) - \\ & 0,324 \tanh(W_{t-1}^{(1)*}) + 0,151 \tanh(W_{t-1}^{(2)*}) + 0,342 \tanh(W_{t-1}^{(3)*}) - 0,4 \tanh(W_{t-1}^{(4)*}). \\ f(x_5) = & -0,382 - 0,019 \tanh(N_{t-1}^{(1)*}) - 0,395 \tanh(N_{t-1}^{(2)*}) + 0,172 \tanh(N_{t-1}^{(3)*}) + 0,435 \tanh(N_{t-1}^{(4)*}) - \\ & 0,396 \tanh(W_{t-1}^{(1)*}) + 0,274 \tanh(W_{t-1}^{(2)*}) + 0,199 \tanh(W_{t-1}^{(3)*}) + 0,304 \tanh(W_{t-1}^{(4)*}). \\ f(x_6) = & -0,442 + 0,363 \tanh(N_{t-1}^{(1)*}) + 0,148 \tanh(N_{t-1}^{(2)*}) - 0,355 \tanh(N_{t-1}^{(3)*}) - 0,382 \tanh(N_{t-1}^{(4)*}) + \\ & 0,345 \tanh(W_{t-1}^{(1)*}) + 0,025 \tanh(W_{t-1}^{(2)*}) - 0,136 \tanh(W_{t-1}^{(3)*}) - 0,285 \tanh(W_{t-1}^{(4)*}). \\ f(x_7) = & -0,122 + 0,422 \tanh(N_{t-1}^{(1)*}) - 0,309 \tanh(N_{t-1}^{(2)*}) - 0,362 \tanh(N_{t-1}^{(3)*}) - 0,009 \tanh(N_{t-1}^{(4)*}) - \\ & 0,31 \tanh(W_{t-1}^{(1)*}) - 0,054 \tanh(W_{t-1}^{(2)*}) + 0,516 \tanh(W_{t-1}^{(3)*}) - 0,32 \tanh(W_{t-1}^{(4)*}). \\ f(x_8) = & -0,507 - 0,333 \tanh(N_{t-1}^{(1)*}) + 0,088 \tanh(N_{t-1}^{(2)*}) + 0,136 \tanh(N_{t-1}^{(3)*}) - 0,448 \tanh(N_{t-1}^{(4)*}) + \\ & 0,389 \tanh(W_{t-1}^{(1)*}) - 0,109 \tanh(W_{t-1}^{(2)*}) - 0,387 \tanh(W_{t-1}^{(3)*}) - 0,317 \tanh(W_{t-1}^{(4)*}). \\ f(x_9) = & 0,04 + 0,343 \tanh(N_{t-1}^{(1)*}) - 0,449 \tanh(N_{t-1}^{(2)*}) + 0,249 \tanh(N_{t-1}^{(3)*}) - 0,012 \tanh(N_{t-1}^{(4)*}) - \\ & 0,153 \tanh(W_{t-1}^{(1)*}) + 0,185 \tanh(W_{t-1}^{(2)*}) + 0,372 \tanh(W_{t-1}^{(3)*}) - 0,388 \tanh(W_{t-1}^{(4)*}). \\ f(x_{10}) = & 0,391 + 0,412 \tanh(N_{t-1}^{(1)*}) + 0,259 \tanh(N_{t-1}^{(2)*}) + 0,371 \tanh(N_{t-1}^{(3)*}) + 0,156 \tanh(N_{t-1}^{(4)*}) - \\ & 0,108 \tanh(W_{t-1}^{(1)*}) + 0,383 \tanh(W_{t-1}^{(2)*}) - 0,086 \tanh(W_{t-1}^{(3)*}) - 0,354 \tanh(W_{t-1}^{(4)*}). \\ f(x_{11}) = & 0,393 + 0,111 \tanh(N_{t-1}^{(1)*}) + 0,455 \tanh(N_{t-1}^{(2)*}) + 0,173 \tanh(N_{t-1}^{(3)*}) - 0,368 \tanh(N_{t-1}^{(4)*}) - \\ & 0,326 \tanh(W_{t-1}^{(1)*}) + 0,494 \tanh(W_{t-1}^{(2)*}) - 0,21 \tanh(W_{t-1}^{(3)*}) - 0,336 \tanh(W_{t-1}^{(4)*}).\end{aligned}$$

$$\begin{aligned}
f(x_{12}) &= 0,342 - 0,36 \tanh(N_{t-1}^{(1)*}) - 0,142 \tanh(N_{t-1}^{(2)*}) + 0,467 \tanh(N_{t-1}^{(3)*}) + 0,287 \tanh(N_{t-1}^{(4)*}) - \\
&\quad 0,203 \tanh(W_{t-1}^{(1)*}) + 0,033 \tanh(W_{t-1}^{(2)*}) + 0,266 \tanh(W_{t-1}^{(3)*}) + 0,001 \tanh(W_{t-1}^{(4)*}). \\
f(x_{13}) &= 0,472 + 0,247 \tanh(N_{t-1}^{(1)*}) - 0,297 \tanh(N_{t-1}^{(2)*}) + 0,451 \tanh(N_{t-1}^{(3)*}) - 0,07 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,136 \tanh(W_{t-1}^{(1)*}) + 0,333 \tanh(W_{t-1}^{(2)*}) - 0,159 \tanh(W_{t-1}^{(3)*}) + 0,028 \tanh(W_{t-1}^{(4)*}). \\
f(x_{14}) &= -0,31 + 0,319 \tanh(N_{t-1}^{(1)*}) - 0,342 \tanh(N_{t-1}^{(2)*}) - 0,422 \tanh(N_{t-1}^{(3)*}) + 0,33 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,103 \tanh(W_{t-1}^{(1)*}) - 0,471 \tanh(W_{t-1}^{(2)*}) - 0,037 \tanh(W_{t-1}^{(3)*}) + 0,135 \tanh(W_{t-1}^{(4)*}). \\
f(x_{15}) &= 0,439 - 0,174 \tanh(N_{t-1}^{(1)*}) + 0,11 \tanh(N_{t-1}^{(2)*}) - 0,262 \tanh(N_{t-1}^{(3)*}) + 0,208 \tanh(N_{t-1}^{(4)*}) - \\
&\quad 0,107 \tanh(W_{t-1}^{(1)*}) - 0,320 \tanh(W_{t-1}^{(2)*}) + 0,458 \tanh(W_{t-1}^{(3)*}) - 0,275 \tanh(W_{t-1}^{(4)*}).
\end{aligned}$$



Gambar 4.58 Arsitektur GSTAR-FFNN Bobot Invers Jarak Pemodelan Residual Tahap I Data *Outflow*

Berikut adalah *time series plot* data aktual dan ramalan dengan menggunakan model *hybrid* GSTARX-FFNN(8,15,1) bobot invers jarak.



Gambar 4.59 Perbandingan Data *Outflow* Aktual dan Ramalan Model GSTARX-FFNN

Berdasarkan Gambar 4.59 terlihat bahwa hasil ramalan menggunakan model GSTARX-FFNN sudah mampu menangkap pola variasi kalender meskipun masih ada jarak yang relatif lebar antara data ramalan dan data aktual.

IV. Pemodelan *Outflow* Tahap Kedua Menggunakan *Hybrid* GSTAR-DLNN


Pada pemodelan *hybrid* GSTAR-DLNN, *input* yang digunakan adalah semua variabel model GSTAR yang terdiri dari 8 variabel *input*. Penentuan banyaknya *neuron* dilakukan dengan metode *cross validation* dengan banyaknya *neuron* pada *hidden layer* pertama adalah 1, 2, 3, 4, 5, 10, dan 15, sedangkan *hidden layer* kedua jumlah *neuron* yang digunakan adalah 1, 2, 3, 4, 5. Fungsi aktivasi pada *hidden layer* adalah *hyperbolic tangent*, sedangkan fungsi aktivasi untuk *output layer* adalah linier. *Neuron* optimal yang terpilih adalah *neuron* yang menghasilkan tingkat kesalahan terkecil pada data *testing*. Arsitektur pemodelan *hybrid* GSTAR-DLNN dapat dilihat pada Gambar 4.48.

Hasil evaluasi model untuk data residual *outflow* menggunakan *hybrid* GSTARX-DLNN untuk masing-masing bobot disajikan pada Lampiran 49-51, berikut adalah model terbaik masing-masing bobot.

Tabel 4.54 Nilai Keباikan Model *hybrid* GSTARX-DLNN Data *Outflow*

Bobot	Model	RMSE <i>In Sample</i>				RMSE <i>Out Sample</i>			
		Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
Seragam	GSTARX-DLNN (8,15,5,1)	464,447	126,085	200,123	99,105	933,073	513,293	435,772	294,533
Invers Jarak	GSTARX-DLNN (8,10,5,1)	464,881	125,780	204,756	97,318	944,847	500,736	454,558	286,515
NIKSP	GSTARX-DLNN (8,15,4,1)	463,845	123,491	202,433	98,269	954,208	495,066	444,023	281,165

Berdasarkan Tabel 4.54 model terbaik dengan menggunakan bobot seragam terdiri dari 15 unit *neuron* pada *hidden layer* pertama dan 5 unit *neuron* pada *hidden layer* kedua. Model terbaik dengan bobot invers jarak terdiri dari 10 unit *neuron* pada *hidden layer* pertama dan 5 unit *neuron* pada *hidden layer* kedua. Sedangkan dengan menggunakan bobot NIKSP model terbaik terdiri dari 15 unit *neuron* pada *hidden layer* pertama dan 4 unit *neuron* pada *hidden layer* kedua. Diantara ketiga bobot, model *hybrid* GSTARX-DLNN(8,15,4,1) dengan bobot NIKSP memberikan kesalahan ramalan minimum berdasarkan kriteria RMSE *out sample*. Arsitektur untuk model GSTAR-DLNN bobot NIKSP dengan 8 *input*, 15 unit *neuron* pada *hidden layer* pertama dan 4 unit *neuron* pada *hidden layer* kedua ditampilkan pada Gambar 4.60.



Gambar 4.60 Arsitektur GSTAR-DLNN Bobot NIKSP Residual Tahap I Data *Outflow*

Persamaan matematis untuk mendapatkan perhitungan manual seperti persamaan (4.12) dengan, $\hat{Z}_t^{(1)}$ pemodelan pada tahap pertama seperti pada persamaan (4.18) dan $\hat{N}_t^{(2)}$ merupakan pemodelan tahap kedua menggunakan *hybrid* GSTAR-DLNN(8,15,4,1) dengan persamaan sebagai berikut (estimasi parameter pada Lampiran 50)

Persamaan pada *output layer*.

$$\hat{N}_t^* = -0,009 + 0,075f(x_{2,1}) - 0,277f(x_{2,2}) + 0,019f(x_{2,3}) + 0,1f(x_{2,4}).$$

dengan N_t^* = nilai *standardized* dari N_t .

Persamaan pada *hidden layer* kedua sebagai berikut


$$\begin{aligned}
f(x_{2,1}) &= -0,368 + 0,243 \tanh(f(x_{1,1})) - 0,2 \tanh(f(x_{1,2})) - 0,151 \tanh(f(x_{1,3})) + \\
&\quad 0,125 \tanh(f(x_{1,4})) - 0,43 \tanh(f(x_{1,5})) - 0,255 \tanh(f(x_{1,6})) - 0,379 \tanh(f(x_{1,7})) - \\
&\quad 0,127 \tanh(f(x_{1,8})) - 0,338 \tanh(f(x_{1,9})) + 0,351 \tanh(f(x_{1,10})) + 0,085 \tanh(f(x_{1,11})) - \\
&\quad 0,182 \tanh(f(x_{1,12})) - 0,106 \tanh(f(x_{1,13})) - 0,501 \tanh(f(x_{1,14})) - 0,009 \tanh(f(x_{1,15})). \\
f(x_{2,2}) &= 0,346 + 0,422 \tanh(f(x_{1,1})) + 0,041 \tanh(f(x_{1,2})) + 0,318 \tanh(f(x_{1,3})) + \\
&\quad 0,383 \tanh(f(x_{1,4})) - 0,017 \tanh(f(x_{1,5})) - 0,051 \tanh(f(x_{1,6})) - 0,259 \tanh(f(x_{1,7})) + \\
&\quad 0,088 \tanh(f(x_{1,8})) - 0,43 \tanh(f(x_{1,9})) - 0,403 \tanh(f(x_{1,10})) - 0,09 \tanh(f(x_{1,11})) - \\
&\quad 0,091 \tanh(f(x_{1,12})) - 0,19 \tanh(f(x_{1,13})) - 0,036 \tanh(f(x_{1,14})) + 0,352 \tanh(f(x_{1,15})). \\
f(x_{2,3}) &= -0,206 - 0,117 \tanh(f(x_{1,1})) + 0,35 \tanh(f(x_{1,2})) - 0,212 \tanh(f(x_{1,3})) - \\
&\quad 0,008 \tanh(f(x_{1,4})) - 0,255 \tanh(f(x_{1,5})) + 0,088 \tanh(f(x_{1,6})) - 0,44 \tanh(f(x_{1,7})) - \\
&\quad 0,244 \tanh(f(x_{1,8})) + 0,419 \tanh(f(x_{1,9})) + 0,46 \tanh(f(x_{1,10})) + 0,079 \tanh(f(x_{1,11})) + \\
&\quad 0,394 \tanh(f(x_{1,12})) + 0,349 \tanh(f(x_{1,13})) - 0,3 \tanh(f(x_{1,14})) + 0,087 \tanh(f(x_{1,15})). \\
f(x_{2,4}) &= -0,244 + 0,417 \tanh(f(x_{1,1})) + 0,414 \tanh(f(x_{1,2})) + 0,497 \tanh(f(x_{1,3})) - \\
&\quad 0,5 \tanh(f(x_{1,4})) - 0,068 \tanh(f(x_{1,5})) + 0,381 \tanh(f(x_{1,6})) + 0,42 \tanh(f(x_{1,7})) + \\
&\quad 0,332 \tanh(f(x_{1,8})) - 0,207 \tanh(f(x_{1,9})) + 0,382 \tanh(f(x_{1,10})) - 0,088 \tanh(f(x_{1,11})) + \\
&\quad 0,221 \tanh(f(x_{1,12})) - 0,198 \tanh(f(x_{1,13})) + 0,336 \tanh(f(x_{1,14})) - 0,346 \tanh(f(x_{1,15})).
\end{aligned}$$

Persamaan pada *hidden layer* pertama sebagai berikut


$$\begin{aligned}
f(x_{1,1}) &= 0,462 + 0,092 \tanh(\mathbf{N}_{t-1}^{(1)*}) - 0,159 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,19 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,372 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
&\quad 0,218 \tanh(\mathbf{W}_{t-1}^{(1)*}) + 0,379 \tanh(\mathbf{W}_{t-1}^{(2)*}) + 0,139 \tanh(\mathbf{W}_{t-1}^{(3)*}) + 0,039 \tanh(\mathbf{W}_{t-1}^{(4)*}). \\
f(x_{1,2}) &= -0,076 - 0,408 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,405 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,169 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,131 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
&\quad 0,171 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,088 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,101 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,086 \tanh(\mathbf{W}_{t-1}^{(4)*}). \\
f(x_{1,3}) &= -0,218 + 0,216 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,368 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,174 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,496 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
&\quad 0,363 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,335 \tanh(\mathbf{W}_{t-1}^{(2)*}) + 0,299 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,14 \tanh(\mathbf{W}_{t-1}^{(4)*}). \\
f(x_{1,4}) &= -0,444 + 0,142 \tanh(\mathbf{N}_{t-1}^{(1)*}) + 0,337 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,354 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,334 \tanh(\mathbf{N}_{t-1}^{(4)*}) - \\
&\quad 0,038 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,215 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,006 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,496 \tanh(\mathbf{W}_{t-1}^{(4)*}). \\
f(x_{1,5}) &= -0,461 - 0,185 \tanh(\mathbf{N}_{t-1}^{(1)*}) - 0,482 \tanh(\mathbf{N}_{t-1}^{(2)*}) + 0,058 \tanh(\mathbf{N}_{t-1}^{(3)*}) + 0,47 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
&\quad 0,089 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,038 \tanh(\mathbf{W}_{t-1}^{(2)*}) - 0,046 \tanh(\mathbf{W}_{t-1}^{(3)*}) - 0,24 \tanh(\mathbf{W}_{t-1}^{(4)*}). \\
f(x_{1,6}) &= 0,236 + 0,235 \tanh(\mathbf{N}_{t-1}^{(1)*}) - 0,471 \tanh(\mathbf{N}_{t-1}^{(2)*}) - 0,128 \tanh(\mathbf{N}_{t-1}^{(3)*}) - 0,346 \tanh(\mathbf{N}_{t-1}^{(4)*}) + \\
&\quad 0,244 \tanh(\mathbf{W}_{t-1}^{(1)*}) - 0,324 \tanh(\mathbf{W}_{t-1}^{(2)*}) + 0,487 \tanh(\mathbf{W}_{t-1}^{(3)*}) + 0,463 \tanh(\mathbf{W}_{t-1}^{(4)*}).
\end{aligned}$$

$$\begin{aligned}
f(x_{1,7}) &= 0,019 - 0,298 \tanh(N_{t-1}^{(1)*}) + 0,337 \tanh(N_{t-1}^{(2)*}) - 0,398 \tanh(N_{t-1}^{(3)*}) + 0,29 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,224 \tanh(W_{t-1}^{(1)*}) + 0,069 \tanh(W_{t-1}^{(2)*}) + 0,193 \tanh(W_{t-1}^{(3)*}) - 0,461 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,8}) &= 0,138 + 0,155 \tanh(N_{t-1}^{(1)*}) - 0,428 \tanh(N_{t-1}^{(2)*}) - 0,151 \tanh(N_{t-1}^{(3)*}) + 0,309 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,341 \tanh(W_{t-1}^{(1)*}) + 0,333 \tanh(W_{t-1}^{(2)*}) + 0,243 \tanh(W_{t-1}^{(3)*}) - 0,48 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,9}) &= 0,433 + 0,074 \tanh(N_{t-1}^{(1)*}) - 0,293 \tanh(N_{t-1}^{(2)*}) - 0,1 \tanh(N_{t-1}^{(3)*}) + 0,317 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,122 \tanh(W_{t-1}^{(1)*}) - 0,239 \tanh(W_{t-1}^{(2)*}) + 0,075 \tanh(W_{t-1}^{(3)*}) + 0,491 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,10}) &= 0,11 + 0,264 \tanh(N_{t-1}^{(1)*}) + 0,404 \tanh(N_{t-1}^{(2)*}) + 0,321 \tanh(N_{t-1}^{(3)*}) + 0,075 \tanh(N_{t-1}^{(4)*}) - \\
&\quad 0,191 \tanh(W_{t-1}^{(1)*}) - 0,36 \tanh(W_{t-1}^{(2)*}) - 0,371 \tanh(W_{t-1}^{(3)*}) - 0,435 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,11}) &= -0,491 + 0,228 \tanh(N_{t-1}^{(1)*}) - 0,372 \tanh(N_{t-1}^{(2)*}) + 0,054 \tanh(N_{t-1}^{(3)*}) + 0,213 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,008 \tanh(W_{t-1}^{(1)*}) + 0,46 \tanh(W_{t-1}^{(2)*}) + 0,137 \tanh(W_{t-1}^{(3)*}) - 0,179 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,12}) &= -0,039 - 0,273 \tanh(N_{t-1}^{(1)*}) + 0,263 \tanh(N_{t-1}^{(2)*}) - 0,344 \tanh(N_{t-1}^{(3)*}) - 0,498 \tanh(N_{t-1}^{(4)*}) - \\
&\quad 0,267 \tanh(W_{t-1}^{(1)*}) - 0,417 \tanh(W_{t-1}^{(2)*}) + 0,438 \tanh(W_{t-1}^{(3)*}) - 0,389 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,13}) &= 0,282 - 0,444 \tanh(N_{t-1}^{(1)*}) + 0,226 \tanh(N_{t-1}^{(2)*}) - 0,489 \tanh(N_{t-1}^{(3)*}) + 0,019 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,285 \tanh(W_{t-1}^{(1)*}) + 0,209 \tanh(W_{t-1}^{(2)*}) - 0,379 \tanh(W_{t-1}^{(3)*}) - 0,447 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,14}) &= 0,298 + 0,392 \tanh(N_{t-1}^{(1)*}) - 0,344 \tanh(N_{t-1}^{(2)*}) - 0,311 \tanh(N_{t-1}^{(3)*}) - 0,36 \tanh(N_{t-1}^{(4)*}) + \\
&\quad 0,269 \tanh(W_{t-1}^{(1)*}) - 0,379 \tanh(W_{t-1}^{(2)*}) + 0,323 \tanh(W_{t-1}^{(3)*}) - 0,341 \tanh(W_{t-1}^{(4)*}). \\
f(x_{1,15}) &= 0,283 - 0,019 \tanh(N_{t-1}^{(1)*}) + 0,286 \tanh(N_{t-1}^{(2)*}) + 0,173 \tanh(N_{t-1}^{(3)*}) + 0,147 \tanh(N_{t-1}^{(4)*}) - \\
&\quad 0,092 \tanh(W_{t-1}^{(1)*}) + 0,189 \tanh(W_{t-1}^{(2)*}) + 0,276 \tanh(W_{t-1}^{(3)*}) - 0,023 \tanh(W_{t-1}^{(4)*}).
\end{aligned}$$

Berikut adalah *time series plot* data aktual dan ramalan dengan menggunakan model *hybrid* GSTARX-DLNN(8,15,4,1) bobot NIKSP.



Gambar 4.61 Perbandingan Data *Outflow* Aktual dan Ramalan Model GSTARX-DLNN



Gambar 4.61 Perbandingan Data *Outflow* Aktual dan Ramalan Model GSTARX-DLNN (lanjutan)

Berdasarkan Gambar 4.61 terlihat bahwa hasil ramalan menggunakan model GSTARX-DLNN sudah mampu menangkap pola variasi kalender tetapi di beberapa titik masih ada jarak yang relatif lebar antara data ramalan dan aktual.

4.2.7 Model Terbaik *Outflow* Uang Kartal di KPw BI Wilayah Jawa Timur

Setelah dilakukan pemodelan data *outflow* dengan VARX, GSTARX, dan *hybrid* GSTARX-ANN, berikut ini ditampilkan perbandingan RMSE untuk masing-masing metode dan bobot lokasi yang digunakan.

Tabel 4.55 Kriteria Kebaikan Model Data *Outflow*

Model (Bobot)	RMSE Out Sample				
	Surabaya	Malang	Kediri	Jember	Rata-rata
VARX	961,901	508,382	465,849	292,195	557,082
GSTARX (Seragam)	879,836	516,891	424,108	291,600	528,109
GSTARX (Invers Jarak)	884,596	516,756	420,238	290,927	528,129
GSTARX (NIKSP)	935,234	516,121	419,952	290,339	540,412
GSTARX-FFNN (Seragam)	966,487	510,740	434,344	292,193	550,941
GSTARX-FFNN (Invers Jarak)	1008,180	507,027	399,580	284,916	549,926
GSTARX-FFNN (NIKSP)	958,290	502,646	460,931	294,794	554,165
GSTARX-DLNN (Seragam)	933,073	513,293	435,772	294,533	544,168
GSTARX-DLNN (Invers Jarak)	944,847	500,736	454,558	286,515	546,664
GSTARX-DLNN (NIKSP)	954,208	495,066	444,023	281,165	543,616

Berdasarkan rata-rata RMSE terkecil model GSTARX bobot seragam merupakan model terbaik. Tingginya nilai RMSE model *hybrid* GSTARX-DLNN di KPw BI Surabaya menyebabkan rata-rata RMSE model *hybrid* menjadi besar. Sehingga penentuan model terbaik pada pemodelan data *outflow* ditentukan berdasarkan rata-rata nilai RMSE tanpa melibatkan nilai RMSE KPw BI Surabaya. Model *hybrid* GSTARX-FFNN bobot invers jarak merupakan model terbaik. Berikut ditampilkan persentase pengurangan nilai RMSE masing-masing model terhadap model GSTARX-FFNN bobot invers jarak.


Tabel 4.56 Persentase Pengurangan Nilai RMSE Terhadap Model *Hybrid* GSTARX-FFNN Bobot Invers Jarak

Model (Bobot)	Persentase Pengurangan RMSE			
	Surabaya	Malang	Kediri	Jember
VARX	-4,81%	0,27%	14,23%	2,49%
GSTARX (Seragam)	-14,59%	1,91%	5,78%	2,29%
GSTARX (Invers Jarak)	-13,97%	1,88%	4,92%	2,07%
GSTARX (NIKSP)	-7,80%	1,76%	4,85%	1,87%

Pada pemodelan data *outflow*, model *hybrid* GSTARX-FFNN bobot invers jarak mampu mengurangi kesalahan ramalan sebesar 0,27% dibandingkan model VARX di KPw BI Malang, sebesar 14,23% dibandingkan model VARX di KPw BI Kediri, sebesar 2,49% dibandingkan model VARX di KPw BI Jember. Dibandingkan model GSTARX bobot seragam, model *hybrid* GSTARX-FFNN bobot invers jarak mampu mengurangi kesalahan ramalan sebesar 1,91% di KPw BI Malang, sebesar 5,78% di KPw BI Kediri, sebesar 2,49% di KPw BI Jember.

Dibandingkan model GSTARX bobot invers jarak, model *hybrid* GSTARX-FFNN mampu mengurangi kesalahan ramalan sebesar 1,88% di KPw BI Malang, sebesar 4,92% di KPw BI Kediri, sebesar 2,07% di KPw BI Jember. Dibandingkan model GSTARX NIKSP, model *hybrid* GSTARX-FFNN mampu mengurangi kesalahan ramalan sebesar 1,76% di KPw BI Malang, sebesar 4,85% di KPw BI Kediri, sebesar 1,87% di KPw BI Jember.

Untuk mengetahui sampai *k-step* ke berapa model ini bisa memprediksi dengan baik data *outflow* di tiap lokasi dapat dilihat pada Gambar 4.58.



Gambar 4.62 Nilai RMSE Out Sample *k-Step* Outflow di KPw BI Jawa Timur

Pemodelan data *outflow* menggunakan model *hybrid* GSTARX-FFNN (8,15,1) bobot invers jarak sudah cukup baik, hal ini ditunjukkan oleh Gambar 4.62 dimana nilai RMSE *in sample* di bawah nilai standar deviasi. Untuk mengetahui sampai berapa langkah ke depan model ini baik untuk meramalkan data *outflow* dilihat dari nilai RMSE *k-step*. Jika RMSE *k-step* berada di bawah standar deviasi maka ramalan *out sample* untuk *k-step* cukup baik. Namun jika berada di atas standar deviasi, berarti model tidak begitu baik dalam meramalkan data *out sample* sampai *k-step*.

Pada Gambar 4.62 dapat dilihat bahwa ramalan *out sample* pemodelan *hybrid* GSTARX-FFNN pada data *outflow* di KPw BI di Surabaya, Malang, Kediri, dan Jember sudah cukup baik. Ramalan *out sample outflow* di KPw BI Kediri sampai dua belas langkah ke depan masih di bawah standar deviasi. Sedangkan ramalan *out sample outflow* di KPw BI Surabaya, Malang, dan Jember tidak begitu bagus pada *step* ke-7 dimana nilai RMSE di KPw BI Surabaya, Malang, dan Jember mengalami kenaikan yang cukup besar. Hal ini dikarenakan adanya efek lebaran yang terjadi pada bulan Juli minggu ke-4, sehingga *outflow* yang tinggi pada bulan tersebut belum mampu ditangkap dengan baik oleh model *hybrid* GSTARX-FFNN.

4.3 Perbandingan Akurasi Ramalan Data *Inflow* dan *Outflow* di KPw BI Wilayah Jawa Timur dengan Penelitian Sebelumnya

Pada subbab ini akan dibandingkan akurasi ramalan data *inflow* dan *outflow* di KPw BI wilayah Jawa Timur dengan penelitian yang pernah dilakukan oleh Mubarak (2015). Reza memodelkan *inflow* dan *outflow* menggunakan model GSTARX-GLS.

Tabel 4.57 Perbandingan Akurasi Model dengan Penelitian Sebelumnya

Data	Model (Bobot)	RMSE <i>Out Sample</i>			
		Surabaya	Malang	Kediri	Jember
<i>Inflow</i>	GSTARX-GLS (NIKSP)	875,52	497,19	532,66	163,10
	GSTARX-FFNN (Invers Jarak)	1012,20	457,17	417,87	189,55
<i>Outflow</i>	GSTARX-GLS (Seragam)	674,42	448,09	367,61	224,57
	GSTARX-FFNN (Invers Jarak)	1008,18	507,03	399,58	284,92

Berdasarkan Tabel 4.57, pemodelan *inflow* dan *outflow* di KPw BI wilayah Jawa Timur menggunakan *hybrid* GSTARX-ANN tidak lebih bagus dibandingkan penelitian yang pernah dilakukan oleh Mubarak (2015). Hal ini diduga karena pada pemodelan *hybrid* GSTARX-ANN, orde yang digunakan adalah orde GSTAR(1₁), sedangkan penelitian yang dilakukan Mubarak memasukkan unsur subset kedalam model. Sehingga parameter model pada penelitian Mubarak lebih banyak dibandingkan penelitian ini, dimana ada kecenderungan semakin banyak parameter model akan meningkatkan akurasi ramalan (Armstrong, 2001).

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan maka dapat disimpulkan

1. Model *hybrid* GSTARX-ANN menghasilkan kesalahan ramalan yang lebih kecil dibandingkan VARX dan GSTARX dalam meramalkan data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* linier maupun nonlinier.
2. Data *inflow* dan *outflow* di KPw BI wilayah Jawa Timur dipengaruhi oleh tren kebijakan BI, musiman, dan variasi kalender, serta mengandung unsur *nonlinearity*. Pengaruh minggu terjadinya hari raya Idul Fitri juga berpengaruh terhadap tingginya *inflow* dan *outflow*.
3. Berdasarkan kriteria kebaikan model RMSE, pemodelan data *inflow* menggunakan model GSTARX-FFNN(8,2,1) bobot invers jarak merupakan model terbaik, sedangkan pada pemodelan *outflow* model GSTARX-FFNN(8,15,1) merupakan model terbaik.

5.2 Saran

Saran yang dapat diberikan untuk penelitian selanjutnya adalah memasukkan unsur *subset* pada model GSTAR untuk meningkatkan akurasi ramalan. Selain itu, bisa mengembangkan model *1-level hybrid* GSTARX-ANN dalam peramalan data *space time* sebagai perbandingan model *2-level hybrid* GSTARX-ANN dalam meramalkan data yang mengandung komponen tren, musiman, variasi kalender, dan deret *noise* linier maupun nonlinier.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Anders, U., dan Korn, O. (1999). Model selection in neural networks. *Neural Networks*, hal. 309-323.
- Apriliadara, M., Suhartono, dan Prastyo, D.D. (2016). VARI-X Model for Currency Inflow and Outflow Forecasting with Eid Fitr Effect in Indonesia. *The 2016 Conference on Fundamental and Applied Science for Advanced Technology*.
- Armstrong, J. S. (2001). *Principles of Forecasting: A Handbook for Researchers and Practitioners*. Norwell, MA: Kluwer Academic Publishers.
- Anastasiadis, A. D., Magoulas, G. D., dan Vrahatis, M. N. (2005). New globally convergent training scheme based on the resilient propagation algorithm. *Neurocomputing*, 64, hal. 253-270.
- Baltagi, B. (1980). *On Seemingly Unrelated Regressions with Error Components*. *Econometrica*, 48, hal. 1547-1551.
- Bengio, Y., Lamblin, P., Popovici, D., dan Larochelle, H. (2007). Greedy layer-wise training of deep networks. *Advances in neural information processing systems* 19, hal. 153-160.
- Bank Indonesia. (2013). *Statistik* [online]. Diakses 21 Agustus 2017, dari <http://www.bi.go.id/id/statistik/metadata/SSKI/Contents/Default.aspx>.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. (2002). Generalized STAR models with experimental weights. *Proceedings of the 17th International Workshop on Statistical Modelling 2002*. Eds: Stasinopoulos, M. dan Touloumi, G. Chania. Hal. 143-152.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. (2008). Consistency and asymptotic normality of least square estimators in generalized STAR models. *Statistica Neerlandica*, Vol. 62, No.4, hal. 482-508.
- Bowerman, B.L., dan O'Connell, R.T. (1993). *Forecasting and Time Series: An Applied Approach* (3th ed.). California: Duxbury Press.

- Box, G.E.P., Jenkins, G.M., dan Reinsel, G.C. (2008). *Time Series Analysis: Forecasting and Control* (4th ed.). New Jersey: Prentice Hall.
- Cheng, T., Wang, J., Haworth, J., Heydecker, B., dan Chow, A. (2014). A Dynamic Spatial Weight Matrix and Localized Space–Time Autoregressive Integrated Moving Average for Network Modeling. *Geographical Analysis*, Vol. 46, hal. 75-97.
- Cliff, A.D., dan Ord, J.K. (1975). Space-time modeling with an application to regional forecasting. *Transactions of the Institute of British Geographers*, No. 64, hal.119-128.
- Crone, S.F., dan Kourentzes, N. (2009). Input-variable Specification for Neural Networks - an Analysis of Forecasting low and high Time Series Frequency. *International Joint Conference on Neural Networks*, hal. 14-19.
- Cryer, J.D., dan Chan, K. (2008). *Time Series Analysis: With Application in R* (2nd ed.). New York: Springer Science+Business Media.
- Epperson, B.K. (1993). Spatial and Space-Time Correlations in Systems of Subpopulations With Genetic Drift and Migration. *Genetics*, Vol. 133, hal. 711-727.
- Fausett, L.V. (1994). *Fundamental of Neural Network: Architectures, Algorithm, and Aplications*. New Jersey: Prentice Hall Inc.
- Fok, D., Dijk, D.v., dan Franses, P.H. (2005). A Multi-Level Panel STAR Model For US Manufacturing Sectors. *Journal of Applied Econometrics*, Vol. 20, hal. 811-827.
- Franses, P.H., dan Dijk, D.v. (2000). *Non-Linear Time Series Models in Empirical Finance*. Cambridge University Press.
- Franses, P.H., dan Griensven, K.v. (1998). Forecasting Exchange Rates Using Neural Networks for Technical Trading Rules. *Studies in Nonlinear Dynamics and Econometrics*, Vol. 2, issue 4, hal. 109-114.

- Gencay, R. (1999). Linear, non-linear, and essential foreign exchange rate prediction with simple technical trading rules. *Journal of International Economics*, Vol. 47, hal. 91-107.
- Gencay, R., dan Stengos, T. (1995). Moving Average Rules, Volume and the Predictability of Security Returns with Feedforward Networks. *Journal of Forecasting*, Vol. 17, hal. 401-414.
- Giacinto, V.D. (2006). A Generalized Space-Time ARMA Model with an Application to Regional Unemployment Analysis in Italy. *International Regional Science Review* Vol 29, No. 2, hal. 159–198.
- Granger, C.W.J., dan Teräsvirta, T. (1993). *Modelling Nonlinear Economic Relationships*. Oxford University Press.
- Gulliver, J., dan Briggs, D.J. (2005). Time–space modeling of journey-time exposure to traffic-related air pollution using GIS. *Environmental Research*, Vol. 97, hal. 10-25.
- Grubb, H. (1992). A Multivariate Time Series Analysis of Some Flour Price Data. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Vol. 41, No. 1, hal. 95-107.
- Haefke, C., dan Helmenstein, C. (1995). A Neural Network Model to Exploit the Econometric Properties of Austrian IPOs. *Computational Intelligence for Financial Engineering*, Proceeding of the IEEE/IAFE, hal. 9-15.
- Hannan, E.J. (1970). *Multiple Time Series*. New York: John Wiley & Sons.
- Hyndman, R.J., dan Athanasopoulos, G. (2014). *Forecasting: Principles and Practice*. Otexts.
- Hyndman, R. J., dan Koehler, A. B. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*. Hal. 679-688.
- Kamarianakis, Y., dan Prastacos, P. (2005). Space-time modeling of traffic flow. *Computers and Geosciences*, Vol 31, hal. 119-133.

- Kuan, C.M., dan Liu, T. (1995). Forecasting Exchange Rates using feedforward and Recurrent neural Networks. *Journal of Applied Econometrics*, Vol. 10, hal. 347-364.
- Lee, M.H., Suhartono, dan Hamzah, N.A. (2010). Calender variation model based on ARIMAX for forecasting sales data with Ramadhan effect. *Proceedings of the Regional Conference on Statistical Science*, hal. 349-361.
- Liu, L.M. (2006). *Time Series Analysis and Forecasting*. Illinois: Scientific Computing Associates.
- Makridakis, S. dan Hibon, M. (2000). The M3-Cmpetition: result, conclusions and implications. *International Journal of Forecasting* 16, hal. 451-476.
- Mubarak, R. (2015). *Model Generalized Space-Time Autoregressive with Exogenous Variables untuk Peramalan Arus Uang di Bank Indonesia Wilayah Jawa Timur*. Laporan Tesis. Institut Teknologi Sepuluh Nopember, Surabaya.
- Öller, L.E. (1985). Macroeconomic Forecasting with A Vector ARIMA Model: A Case Study of The Finnish Economy. *International Journal of Forecasting*, Vol. 1, North-Holland, hal. 143-150.
- Pena, D., dan Rodriguez, J. (2002). *A Powerful Portmanteau Test of Lack of Fit for Time Series*. Journal of the American Statistical Association, Vol. 97, No. 458, hal. 601-610.
- Pfeifer, P.E., dan Deutsch, S.J. (1980a). A Three Stage Iterative Procedure for Space-Time Modeling. *Technometrics*, Vol. 22, No. 1, hal. 35-47.
- Pfeifer, P.E., dan Deutsch, S.J. (1980b). Identification and Interpretation of First Order Space-Time ARMA Models. *Technometrics*, Vol. 22, No. 1, hal. 397-408.
- Pfeifer, P.E., dan Deutsch, S.J. (1980c). Stationary and invertibility regions for low order STARMA models. *Communications in Statistics - Simulation and Computation* 9:5, hal. 551-562.

- Prayoga, I.G.S.A. (2016). *Hierarchical Forecasting of Currency Inflow and Outflow in Bank Indonesia Based on Hybrid ARIMAX-ANN Model*. Thesis. Institut Teknologi Sepuluh Nopember, Surabaya.
- Prayoga, I.G.S.A., Suhartono, dan Rahayu, S.P. (2017a). Forecasting Currency Circulation Data of Bank Indonesia by using Hybrid ARIMAX-ANN Model. *The 3rd ISM International Statistical Conference*.
- Prayoga, I.G.S.A., Suhartono, dan Rahayu, S.P. (2017b). Top-down Forecasting for High Dimensional Currency Circulation Data of Bank Indonesia. *International Journal of Advances in Soft Computing & Its Applications*, Vol. 9, Issue 2, hal. 62-74.
- Qi, M., dan Maddala, G.S. (1999). Economic Factors and the Stock Market: A New Perspective. *Journal of Forecasting*, Vol. 18, hal. 151-166.
- Ruchjana, B.N. (2002). Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi S-TAR¹. *Forum Statistika dan Komputasi*, ISSN 0853-8115, hal. 1-6.
- Stoffer, D.S. (1986). Estimation and Identification of Space-Time ARMAX Models in the Presence of Missing Data. *Journal of the American Statistical Association*, 81:395, hal. 762-772.
- Suhartono. (2007). *Feedforward Neural Network untuk Pemodelan Runtun Waktu*. Laporan Disertasi. Universitas Gajah Mada, Yogyakarta.
- Suhartono dan Atok, R.M. (2006). Pemilihan bobot lokasi yang optimal pada model GSTAR. *Prosiding Konferensi Nasional Matematika XIII*, Universitas Negeri Semarang.
- Suhartono dan Subanar. (2006). The Optimal Determination Of Space Weight in GSTAR Model by Using Cross-Correlation Inference. *Journal of Quantitative Methods*, Vol. 2, No. 2, hal. 45-53.
- Suhartono dan Subanar (2007). *Some Comments on the Theorem Providing Stationerity Condition for GSTAR Models in the Paper by Borovkova et al.*

- Journal of The Indonesian Mathematical Society (MIHMI), Vol. 13, No. 1, hal. 44-52.
- Suhartono, Wahyuningrum, S.R., Setiawan, dan Akbar, M.S. (2016). GSTARX-GLS Model for Spatio-Temporal Data Forecasting. *Malaysian Journal of Mathematical Sciences*, Vol. 10, hal. 91-103.
- Swanson, N.R., dan White. H. (1995). *A Model-Selection Approach to Assessing the Information in the Term Structure Using Linear Models and Artificial Neural Networks*. *Journal of Business & Economic Statistics*, Vol. 13, No. 3, hal. 265-275.
- Taylor, J.W. (2000). A Quantile Regression Neural Network Approach to Estimating the Conditional Density of Multiperiod Returns. *Journal of Forecasting*, hal. 299-311.
- Telbany, M.E. (2014). What Quantile Regression Neural Networks Tell us About Prediction of Drug Activities. *10th International Computer Engineering Conference*, hal. 76-80.
- Terasvista, T., Lin, C.F., dan Granger, C.W.J. (1993). Power of The Neural Network Linearity Test. *Journal of Time Series Analysis*, Vol. 14, hal 159-171.
- Tong, H. (1990). *Non-Linear Time Series: A Dynamical System Approach*. Oxford University Press.
- Tsay, R.S. (2002). *Analysis of Financial Time series*. Canada: John Wiley & Sons.
- Wahyuningrum, S.R. (2014). *Model GSTAR-SUR untuk Peramalan Data Spatio-Temporal*. Laporan Tesis. Institut Teknologi Sepuluh Nopember, Surabaya.
- Wei, W.W.S. (2006). *Time Series Analysis: Univariate and Multivariate Methods* (2nd ed.). New York: Addison Wesley.
- Wulansari, R.E., Suryanto, E., Ferawati, K., Andalita, I., dan Suhartono. (2014). Penerapan Time Series Regression with Calendar Variation Effect pada Data Netflow Uang Kartal Bank Indonesia Sebagai Solusi Kontrol

- Likuiditas Perbankan di Indonesia. *Statistika: Forum Teori dan Aplikasi Statistika*, Vol. 14, No. 2, hal. 59-68.
- Wutsqa, D.U., dan Suhartono. (2010). Peramalan Deret Waktu Multivariat Seasonal pada Data Pariwisata dengan Model Var-Gstar. *Jurnal ILMU DASAR*, Vol. 11, No. 1, hal. 101-109.
- Wutsqa, D.U., Suhartono, dan Sutijo, B. (2010). Generalized Space-Time Autoregressive Modeling. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Application (ICMSA 2010)*. Eds: Shean, N.W., Wen, G.K., Leen, K.H., Wah, O.K., dan Ken, Y.L. Universiti Tunku Abdul Rahman, Kuala Lumpur, Malaysia.
- Yunus, K., Chen, P., dan Thiringer, T. (2016). Modelling spatially and temporally correlated wind speed time series over a large geographical area using VARMA. *IET Renewable Power Generation*, Vol. 11, No. 1, hal. 132-142.
- Zellner, A. (1962). An efficient method of estimating seemingly unrelated regression equations and tests for aggregation bias. *Journal of the American Statistical Association*, Vol. 57, hal. 348-368.
- Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, Vol. 50, hal. 159-175.
- Zhang, G. P., dan Berardi, V. L. (1998). An investigation of neural networks in thyroid function diagnosis. *Health Care Management Science*, Vol. 1, No. 1, hal. 29-37.

Halaman ini sengaja dikosongkan

Lampiran

Lampiran 1. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 1

2017 246

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.205039	0.002585	79.32	<.0001
S1	1	21.94003	0.508880	43.11	<.0001
S2	1	24.11469	0.510002	47.28	<.0001
S3	1	26.94479	0.511134	52.72	<.0001
S4	1	23.79266	0.512276	46.44	<.0001
S5	1	21.74142	0.513429	42.35	<.0001
S6	1	16.82006	0.520560	32.31	<.0001
S7	1	12.59287	0.534023	23.58	<.0001
S8	1	9.494945	0.535427	17.73	<.0001
S9	1	5.518033	0.541939	10.18	<.0001
S10	1	9.416781	0.553802	17.00	<.0001
S11	1	13.00153	0.549075	23.68	<.0001
S12	1	17.16589	0.532291	32.25	<.0001
V1t	1	30.33852	1.072190	28.30	<.0001
V2t	1	43.53379	0.929122	46.85	<.0001
V3t	1	46.90500	0.926328	50.64	<.0001
V4t	1	50.01470	0.928868	53.84	<.0001
V1t1	1	49.81319	1.075210	46.33	<.0001
V2t1	1	47.43107	0.929041	51.05	<.0001
V3t1	1	38.52751	0.926324	41.59	<.0001
V4t1	1	34.76807	0.926300	37.53	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.228785	0.001939	117.98	<.0001
S1	1	24.79413	0.381754	64.95	<.0001
S2	1	27.73642	0.382596	72.50	<.0001
S3	1	29.42024	0.383445	76.73	<.0001
S4	1	27.42174	0.384302	71.35	<.0001
S5	1	24.91830	0.385167	64.69	<.0001
S6	1	20.67004	0.390516	52.93	<.0001
S7	1	15.42903	0.400616	38.51	<.0001
S8	1	12.62442	0.401669	31.43	<.0001
S9	1	8.689289	0.406554	21.37	<.0001
S10	1	12.86800	0.415454	30.97	<.0001
S11	1	15.91426	0.411908	38.64	<.0001
S12	1	21.02959	0.399317	52.66	<.0001
V1t	1	43.75143	0.804341	54.39	<.0001
V2t	1	49.22499	0.697013	70.62	<.0001
V3t	1	54.29353	0.694917	78.13	<.0001
V4t	1	58.06240	0.696822	83.32	<.0001
V1t1	1	59.35559	0.806606	73.59	<.0001
V2t1	1	54.72548	0.696953	78.52	<.0001
V3t1	1	43.38780	0.694914	62.44	<.0001
V4t1	1	36.33767	0.694896	52.29	<.0001

Lampiran 1. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 1 (lanjutan)

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.236337	0.002052	115.16	<.0001	
S1	1	17.02537	0.404038	42.14	<.0001	
S2	1	21.18434	0.404929	52.32	<.0001	
S3	1	23.91642	0.405828	58.93	<.0001	
S4	1	20.95856	0.406735	51.53	<.0001	
S5	1	16.90626	0.407650	41.47	<.0001	
S6	1	11.81958	0.413312	28.60	<.0001	
S7	1	8.801903	0.424001	20.76	<.0001	
S8	1	5.425558	0.425116	12.76	<.0001	
S9	1	3.354237	0.430286	7.80	<.0001	
S10	1	5.674298	0.439705	12.90	<.0001	
S11	1	9.229450	0.435952	21.17	<.0001	
S12	1	12.23821	0.422626	28.96	<.0001	
V1t	1	36.38592	0.851292	42.74	<.0001	
V2t	1	40.67854	0.737700	55.14	<.0001	
V3t	1	46.98847	0.735482	63.89	<.0001	
V4t	1	51.59924	0.737498	69.97	<.0001	
V1t1	1	48.85430	0.853690	57.23	<.0001	
V2t1	1	47.65746	0.737636	64.61	<.0001	
V3t1	1	40.88895	0.735478	55.60	<.0001	
V4t1	1	37.57286	0.735459	51.09	<.0001	
Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.40904	0.09930	4.12	0.0001	zresid1(t-1)
	AR1_1_2	0.38488	0.10995	3.50	0.0006	zresid2(t-1)
	AR1_1_3	0.18092	0.11586	1.56	0.1202	zresid3(t-1)
zresid2	AR1_2_1	0.13785	0.08916	1.55	0.1239	zresid1(t-1)
	AR1_2_2	0.45752	0.09873	4.63	0.0001	zresid2(t-1)
	AR1_2_3	0.07380	0.10403	0.71	0.4790	zresid3(t-1)
zresid3	AR1_3_1	0.11180	0.09408	1.19	0.2363	zresid1(t-1)
	AR1_3_2	0.21188	0.10418	2.03	0.0435	zresid2(t-1)
	AR1_3_3	0.38603	0.10977	3.52	0.0006	zresid3(t-1)
Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.35696	0.05471	6.52	0.0001	zresid1(t-1)
	AR1_1_2	0.59062	0.08571	6.89	0.0001	zresid2(t-1)
	AR1_1_3	0.00000	0.00000			zresid3(t-1)
zresid2	AR1_2_1	0.00000	0.00000			zresid1(t-1)
	AR1_2_2	0.66825	0.05539	12.06	0.0001	zresid2(t-1)
	AR1_2_3	0.00000	0.00000			zresid3(t-1)
zresid3	AR1_3_1	0.00000	0.00000			zresid1(t-1)
	AR1_3_2	0.40264	0.07712	5.22	0.0001	zresid2(t-1)
	AR1_3_3	0.30209	0.06105	4.95	0.0001	zresid3(t-1)

Lampiran 1. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 1 (lanjutan)

2017 241

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.410666	0.068671	5.98	<.0001
w1	1	0.555130	0.096840	5.73	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.393532	0.075916	5.18	<.0001
w2	1	0.271191	0.068693	3.95	0.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.451296	0.075137	6.01	<.0001
w3	1	0.247837	0.075328	3.29	0.0012

Lampiran 2. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 2

2017 324

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.222574	0.002141	103.96	<.0001
S1	1	20.60849	0.421493	48.89	<.0001
S2	1	22.61835	0.422422	53.54	<.0001
S3	1	25.96956	0.423360	61.34	<.0001
S4	1	22.85729	0.424306	53.87	<.0001
S5	1	21.01216	0.425261	49.41	<.0001
S6	1	15.80835	0.431167	36.66	<.0001
S7	1	11.55079	0.442318	26.11	<.0001
S8	1	8.449714	0.443481	19.05	<.0001
S9	1	4.655251	0.448874	10.37	<.0001
S10	1	8.484421	0.458700	18.50	<.0001
S11	1	10.98333	0.454785	24.15	<.0001
S12	1	15.36779	0.440883	34.86	<.0001
V1t	1	31.45756	0.888069	35.42	<.0001
V2t	1	43.12189	0.769569	56.03	<.0001
V3t	1	46.83587	0.767255	61.04	<.0001
V4t	1	50.09862	0.769358	65.12	<.0001
V1t1	1	50.72666	0.890570	56.96	<.0001
V2t1	1	45.73905	0.769502	59.44	<.0001
V3t1	1	38.86719	0.767251	50.66	<.0001
V4t1	1	35.71320	0.767231	46.55	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.238265	0.001743	136.73	<.0001
S1	1	23.83371	0.343048	69.48	<.0001
S2	1	27.25019	0.343804	79.26	<.0001
S3	1	29.42487	0.344567	85.40	<.0001
S4	1	27.21927	0.345338	78.82	<.0001
S5	1	24.19615	0.346115	69.91	<.0001
S6	1	19.97042	0.350922	56.91	<.0001
S7	1	15.15100	0.359997	42.09	<.0001
S8	1	12.01624	0.360944	33.29	<.0001
S9	1	8.334229	0.365334	22.81	<.0001
S10	1	12.19600	0.373331	32.67	<.0001
S11	1	15.07518	0.370144	40.73	<.0001
S12	1	20.26382	0.358830	56.47	<.0001
V1t	1	43.67080	0.722788	60.42	<.0001
V2t	1	49.74781	0.626343	79.43	<.0001
V3t	1	54.54174	0.624460	87.34	<.0001
V4t	1	56.88763	0.626171	90.85	<.0001
V1t1	1	60.68975	0.724824	83.73	<.0001
V2t1	1	53.98376	0.626288	86.20	<.0001
V3t1	1	43.31542	0.624456	69.37	<.0001
V4t1	1	36.80701	0.624441	58.94	<.0001

Lampiran 2. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 2 (lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.249441	0.001954	127.65	<.0001
S1	1	15.83965	0.384698	41.17	<.0001
S2	1	20.08441	0.385545	52.09	<.0001
S3	1	23.20345	0.386401	60.05	<.0001
S4	1	19.88440	0.387265	51.35	<.0001
S5	1	15.98640	0.388136	41.19	<.0001
S6	1	11.16588	0.393527	28.37	<.0001
S7	1	7.942241	0.403704	19.67	<.0001
S8	1	4.750602	0.404766	11.74	<.0001
S9	1	2.862683	0.409689	6.99	<.0001
S10	1	4.930881	0.418657	11.78	<.0001
S11	1	7.571718	0.415083	18.24	<.0001
S12	1	11.14614	0.402395	27.70	<.0001
V1t	1	35.99126	0.810542	44.40	<.0001
V2t	1	39.42946	0.702387	56.14	<.0001
V3t	1	46.57551	0.700275	66.51	<.0001
V4t	1	52.04297	0.702195	74.11	<.0001
V1t1	1	49.13392	0.812825	60.45	<.0001
V2t1	1	46.63664	0.702326	66.40	<.0001
V3t1	1	40.69241	0.700271	58.11	<.0001
V4t1	1	37.73685	0.700254	53.89	<.0001

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.45422	0.09452	4.81	0.0001	zresid1(t-1)
	AR1_1_2	0.23810	0.09977	2.39	0.0181	zresid2(t-1)
	AR1_1_3	0.17226	0.08613	2.00	0.0470	zresid3(t-1)
zresid2	AR1_2_1	0.08744	0.09648	0.91	0.3660	zresid1(t-1)
	AR1_2_2	0.36862	0.10184	3.62	0.0004	zresid2(t-1)
	AR1_2_3	0.10753	0.08792	1.22	0.2229	zresid3(t-1)
zresid3	AR1_3_1	0.20609	0.10123	2.04	0.0433	zresid1(t-1)
	AR1_3_2	0.11552	0.10685	1.08	0.2811	zresid2(t-1)
	AR1_3_3	0.34007	0.09225	3.69	0.0003	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.48690	0.05524	8.81	0.0001	zresid1(t-1)
	AR1_1_2	0.27769	0.07234	3.84	0.0002	zresid2(t-1)
	AR1_1_3	0.00000	0.00000			zresid3(t-1)
zresid2	AR1_2_1	0.00000	0.00000			zresid1(t-1)
	AR1_2_2	0.48121	0.05891	8.17	0.0001	zresid2(t-1)
	AR1_2_3	0.00000	0.00000			zresid3(t-1)
zresid3	AR1_3_1	0.28835	0.06999	4.12	0.0001	zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.25396	0.07176	3.54	0.0005	zresid3(t-1)

Lampiran 2. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 2 (lanjutan)

The SAS System 09:32 Thursday, December 19,					
2017 378					
The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.451181	0.066300	6.81	<.0001
w1	1	0.409966	0.087484	4.69	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.346105	0.072153	4.80	<.0001
w2	1	0.211948	0.070064	3.03	0.0029
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.367003	0.073582	4.99	<.0001
w3	1	0.307335	0.081540	3.77	0.0002

Lampiran 3. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 3

2017 442

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.212732	0.002556	83.21	<.0001
S1	1	21.31498	0.503276	42.35	<.0001
S2	1	23.44796	0.504385	46.49	<.0001
S3	1	26.57293	0.505505	52.57	<.0001
S4	1	23.41455	0.506635	46.22	<.0001
S5	1	21.16767	0.507775	41.69	<.0001
S6	1	16.19546	0.514827	31.46	<.0001
S7	1	12.29627	0.528142	23.28	<.0001
S8	1	9.392694	0.529531	17.74	<.0001
S9	1	5.376051	0.535971	10.03	<.0001
S10	1	9.367860	0.547703	17.10	<.0001
S11	1	12.42654	0.543028	22.88	<.0001
S12	1	16.77481	0.526429	31.87	<.0001
V1t	1	32.52964	1.060383	30.68	<.0001
V2t	1	43.41572	0.918890	47.25	<.0001
V3t	1	46.09362	0.916127	50.31	<.0001
V4t	1	49.54254	0.918638	53.93	<.0001
V1t1	1	49.35754	1.063369	46.42	<.0001
V2t1	1	47.31937	0.918810	51.50	<.0001
V3t1	1	38.03040	0.916122	41.51	<.0001
V4t1	1	33.97609	0.916099	37.09	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.230533	0.002090	110.33	<.0001
S1	1	24.59191	0.411365	59.78	<.0001
S2	1	28.01436	0.412271	67.95	<.0001
S3	1	29.72359	0.413186	71.94	<.0001
S4	1	27.71529	0.414110	66.93	<.0001
S5	1	24.76743	0.415042	59.67	<.0001
S6	1	20.63331	0.420806	49.03	<.0001
S7	1	15.34204	0.431689	35.54	<.0001
S8	1	12.75474	0.432824	29.47	<.0001
S9	1	8.631709	0.438088	19.70	<.0001
S10	1	12.58116	0.447678	28.10	<.0001
S11	1	15.66370	0.443857	35.29	<.0001
S12	1	21.04753	0.430289	48.91	<.0001
V1t	1	45.09833	0.866728	52.03	<.0001
V2t	1	49.58249	0.751076	66.02	<.0001
V3t	1	54.80150	0.748818	73.18	<.0001
V4t	1	57.45854	0.750870	76.52	<.0001
V1t1	1	59.42912	0.869169	68.37	<.0001
V2t1	1	55.15779	0.751011	73.44	<.0001
V3t1	1	43.02112	0.748814	57.45	<.0001
V4t1	1	36.34385	0.748795	48.54	<.0001

Lampiran 3. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 3 (lanjutan)

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.243293	0.001937	125.58	<.0001	
S1	1	16.46550	0.381406	43.17	<.0001	
S2	1	20.51783	0.382247	53.68	<.0001	
S3	1	23.70938	0.383095	61.89	<.0001	
S4	1	20.32385	0.383951	52.93	<.0001	
S5	1	16.13215	0.384816	41.92	<.0001	
S6	1	11.09923	0.390160	28.45	<.0001	
S7	1	8.203753	0.400250	20.50	<.0001	
S8	1	5.281377	0.401303	13.16	<.0001	
S9	1	3.275006	0.406183	8.06	<.0001	
S10	1	5.464791	0.415075	13.17	<.0001	
S11	1	8.265246	0.411532	20.08	<.0001	
S12	1	11.87664	0.398952	29.77	<.0001	
V1t	1	36.70528	0.803607	45.68	<.0001	
V2t	1	40.59674	0.696378	58.30	<.0001	
V3t	1	46.36446	0.694284	66.78	<.0001	
V4t	1	51.48085	0.696187	73.95	<.0001	
V1t1	1	48.87661	0.805870	60.65	<.0001	
V2t1	1	47.77686	0.696317	68.61	<.0001	
V3t1	1	40.54841	0.694280	58.40	<.0001	
V4t1	1	37.26291	0.694262	53.67	<.0001	

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.39839	0.09481	4.20	0.0001	zresid1(t-1)
	AR1_1_2	0.35864	0.10615	3.38	0.0009	zresid2(t-1)
	AR1_1_3	0.20331	0.11016	1.85	0.0666	zresid3(t-1)
zresid2	AR1_2_1	0.12192	0.09557	1.28	0.2038	zresid1(t-1)
	AR1_2_2	0.33034	0.10700	3.09	0.0023	zresid2(t-1)
	AR1_2_3	0.24080	0.11104	2.17	0.0315	zresid3(t-1)
zresid3	AR1_3_1	0.10990	0.08954	1.23	0.2213	zresid1(t-1)
	AR1_3_2	0.14787	0.10025	1.48	0.1420	zresid2(t-1)
	AR1_3_3	0.38546	0.10403	3.71	0.0003	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.40426	0.05675	7.12	0.0001	zresid1(t-1)
	AR1_1_2	0.37235	0.07103	5.24	0.0001	zresid2(t-1)
	AR1_1_3	0.00000	0.00000			zresid3(t-1)
zresid2	AR1_2_1	0.00000	0.00000			zresid1(t-1)
	AR1_2_2	0.34632	0.06744	5.14	0.0001	zresid2(t-1)
	AR1_2_3	0.22993	0.07188	3.20	0.0016	zresid3(t-1)
zresid3	AR1_3_1	0.00000	0.00000			zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.50639	0.05127	9.88	0.0001	zresid3(t-1)

Lampiran 3. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 3 (lanjutan)

2017 496

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.437756	0.066301	6.60	<.0001
w1	1	0.517102	0.092061	5.62	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.264727	0.077748	3.40	0.0008
w2	1	0.404131	0.079472	5.09	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.403012	0.075639	5.33	<.0001
w3	1	0.239209	0.069691	3.43	0.0007

Lampiran 4. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 4

The SAS System 09:32 Thursday, December 19,

2017 501

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.204576	0.002353	86.94	<.0001
S1	1	22.91849	0.463264	49.47	<.0001
S2	1	24.95715	0.464285	53.75	<.0001
S3	1	27.78765	0.465316	59.72	<.0001
S4	1	24.61970	0.466356	52.79	<.0001
S5	1	22.76778	0.467406	48.71	<.0001
S6	1	17.72455	0.473897	37.40	<.0001
S7	1	13.80820	0.486153	28.40	<.0001
S8	1	10.82988	0.487431	22.22	<.0001
S9	1	6.830061	0.493359	13.84	<.0001
S10	1	10.24141	0.504159	20.31	<.0001
S11	1	13.22705	0.499856	26.46	<.0001
S12	1	17.29387	0.484576	35.69	<.0001
V1t	1	32.44447	0.976079	33.24	<.0001
V2t	1	42.24642	0.845836	49.95	<.0001
V3t	1	47.30871	0.843292	56.10	<.0001
V4t	1	50.30522	0.845604	59.49	<.0001
V1t1	1	49.91488	0.978828	50.99	<.0001
V2t1	1	45.67740	0.845762	54.01	<.0001
V3t1	1	39.10763	0.843288	46.38	<.0001
V4t1	1	34.43333	0.843267	40.83	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.228126	0.001978	115.30	<.0001
S1	1	25.49133	0.389502	65.45	<.0001
S2	1	28.62098	0.390360	73.32	<.0001
S3	1	30.22633	0.391227	77.26	<.0001
S4	1	28.48202	0.392101	72.64	<.0001
S5	1	25.62329	0.392984	65.20	<.0001
S6	1	21.60506	0.398442	54.22	<.0001
S7	1	16.38528	0.408746	40.09	<.0001
S8	1	13.30178	0.409821	32.46	<.0001
S9	1	9.334178	0.414805	22.50	<.0001
S10	1	13.00334	0.423885	30.68	<.0001
S11	1	15.70558	0.420267	37.37	<.0001
S12	1	21.33371	0.407421	52.36	<.0001
V1t	1	45.32199	0.820665	55.23	<.0001
V2t	1	48.71898	0.711159	68.51	<.0001
V3t	1	55.92625	0.709021	78.88	<.0001
V4t	1	57.59885	0.710964	81.02	<.0001
V1t1	1	60.44648	0.822976	73.45	<.0001
V2t1	1	53.26911	0.711097	74.91	<.0001
V3t1	1	44.49869	0.709017	62.76	<.0001
V4t1	1	36.06538	0.708999	50.87	<.0001

Lampiran 4. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 4 (lanjutan)

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.235588	0.002213	106.46	<.0001	
S1	1	17.55554	0.435651	40.30	<.0001	
S2	1	21.85101	0.436611	50.05	<.0001	
S3	1	24.23716	0.437580	55.39	<.0001	
S4	1	21.29862	0.438558	48.57	<.0001	
S5	1	17.65328	0.439545	40.16	<.0001	
S6	1	12.95390	0.445650	29.07	<.0001	
S7	1	9.871020	0.457175	21.59	<.0001	
S8	1	6.725052	0.458377	14.67	<.0001	
S9	1	4.546176	0.463952	9.80	<.0001	
S10	1	6.390335	0.474108	13.48	<.0001	
S11	1	9.148921	0.470061	19.46	<.0001	
S12	1	12.60641	0.455692	27.66	<.0001	
V1t	1	37.10345	0.917898	40.42	<.0001	
V2t	1	39.41793	0.795418	49.56	<.0001	
V3t	1	47.98264	0.793027	60.51	<.0001	
V4t	1	51.56918	0.795200	64.85	<.0001	
V1t1	1	49.17466	0.920484	53.42	<.0001	
V2t1	1	46.05494	0.795349	57.91	<.0001	
V3t1	1	41.54455	0.793022	52.39	<.0001	
V4t1	1	36.61356	0.793002	46.17	<.0001	
Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.47566	0.08566	5.55	0.0001	zresid1(t-1)
	AR1_1_2	0.21924	0.09681	2.26	0.0248	zresid2(t-1)
	AR1_1_3	0.20540	0.08259	2.49	0.0138	zresid3(t-1)
zresid2	AR1_2_1	0.23556	0.09004	2.62	0.0097	zresid1(t-1)
	AR1_2_2	0.32775	0.10176	3.22	0.0015	zresid2(t-1)
	AR1_2_3	0.07373	0.08681	0.85	0.3968	zresid3(t-1)
zresid3	AR1_3_1	0.17437	0.09482	1.84	0.0676	zresid1(t-1)
	AR1_3_2	0.14187	0.10717	1.32	0.1873	zresid2(t-1)
	AR1_3_3	0.43601	0.09142	4.77	0.0001	zresid3(t-1)
Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.42410	0.07027	6.04	0.0001	zresid1(t-1)
	AR1_1_2	0.17949	0.07996	2.24	0.0260	zresid2(t-1)
	AR1_1_3	0.21719	0.06267	3.47	0.0007	zresid3(t-1)
zresid2	AR1_2_1	0.21758	0.06669	3.26	0.0013	zresid1(t-1)
	AR1_2_2	0.31806	0.07825	4.06	0.0001	zresid2(t-1)
	AR1_2_3	0.00000	0.00000			zresid3(t-1)
zresid3	AR1_3_1	0.00000	0.00000			zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.61468	0.05026	12.23	0.0001	zresid3(t-1)

Lampiran 4. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 4 (lanjutan)

The SAS System 09:32 Thursday, December 19,					
2017 555					
The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.427910	0.065982	6.49	<.0001
w1	1	0.478591	0.081227	5.89	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.343397	0.076518	4.49	<.0001
w2	1	0.302566	0.074288	4.07	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.479054	0.073750	6.50	<.0001
w3	1	0.275943	0.082033	3.36	0.0009

Lampiran 5. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 5

2017 560

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.211629	0.002915	72.61	<.0001
S1	1	22.57248	0.573805	39.34	<.0001
S2	1	24.22231	0.575070	42.12	<.0001
S3	1	27.30551	0.576346	47.38	<.0001
S4	1	23.90389	0.577634	41.38	<.0001
S5	1	21.79693	0.578935	37.65	<.0001
S6	1	17.08242	0.586975	29.10	<.0001
S7	1	13.06919	0.602155	21.70	<.0001
S8	1	9.639883	0.603739	15.97	<.0001
S9	1	5.563435	0.611081	9.10	<.0001
S10	1	10.12652	0.624458	16.22	<.0001
S11	1	12.86776	0.619128	20.78	<.0001
S12	1	17.67783	0.600202	29.45	<.0001
V1t	1	32.69053	1.208984	27.04	<.0001
V2t	1	44.97197	1.047663	42.93	<.0001
V3t	1	46.23366	1.044512	44.26	<.0001
V4t	1	48.04242	1.047376	45.87	<.0001
V1t1	1	50.98401	1.212389	42.05	<.0001
V2t1	1	47.77269	1.047572	45.60	<.0001
V3t1	1	38.35907	1.044507	36.72	<.0001
V4t1	1	33.66502	1.044481	32.23	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.232032	0.002295	101.11	<.0001
S1	1	25.26139	0.451802	55.91	<.0001
S2	1	28.10163	0.452797	62.06	<.0001
S3	1	29.87454	0.453802	65.83	<.0001
S4	1	27.80913	0.454817	61.14	<.0001
S5	1	24.58875	0.455840	53.94	<.0001
S6	1	21.28843	0.462171	46.06	<.0001
S7	1	15.98736	0.474124	33.72	<.0001
S8	1	12.56320	0.475371	26.43	<.0001
S9	1	8.331722	0.481152	17.32	<.0001
S10	1	13.21111	0.491684	26.87	<.0001
S11	1	16.19476	0.487487	33.22	<.0001
S12	1	21.51204	0.472586	45.52	<.0001
V1t	1	45.56497	0.951927	47.87	<.0001
V2t	1	50.50842	0.824907	61.23	<.0001
V3t	1	54.17126	0.822426	65.87	<.0001
V4t	1	56.54992	0.824680	68.57	<.0001
V1t1	1	60.60569	0.954608	63.49	<.0001
V2t1	1	56.19964	0.824835	68.13	<.0001
V3t1	1	43.49231	0.822422	52.88	<.0001
V4t1	1	35.74928	0.822401	43.47	<.0001

Lampiran 5. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 5 (lanjutan)

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.241300	0.002372	101.73	<.0001	
S1	1	17.30182	0.466981	37.05	<.0001	
S2	1	21.31724	0.468010	45.55	<.0001	
S3	1	24.04838	0.469049	51.27	<.0001	
S4	1	20.80275	0.470098	44.25	<.0001	
S5	1	16.51452	0.471156	35.05	<.0001	
S6	1	12.00907	0.477699	25.14	<.0001	
S7	1	8.538153	0.490054	17.42	<.0001	
S8	1	5.810682	0.491342	11.83	<.0001	
S9	1	3.822122	0.497318	7.69	<.0001	
S10	1	5.921700	0.508204	11.65	<.0001	
S11	1	9.016830	0.503866	17.90	<.0001	
S12	1	12.34868	0.488464	25.28	<.0001	
V1t	1	37.33575	0.983911	37.95	<.0001	
V2t	1	41.03393	0.852622	48.13	<.0001	
V3t	1	46.00040	0.850058	54.11	<.0001	
V4t	1	50.91762	0.852389	59.74	<.0001	
V1t1	1	49.84505	0.986682	50.52	<.0001	
V2t1	1	48.92450	0.852548	57.39	<.0001	
V3t1	1	40.38430	0.850054	47.51	<.0001	
V4t1	1	37.11069	0.850032	43.66	<.0001	

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.46386	0.09100	5.10	0.0001	zresid1(t-1)
	AR1_1_2	0.18419	0.10702	1.72	0.0870	zresid2(t-1)
	AR1_1_3	0.34506	0.09563	3.61	0.0004	zresid3(t-1)
zresid2	AR1_2_1	0.20716	0.08731	2.37	0.0187	zresid1(t-1)
	AR1_2_2	0.18419	0.10268	1.79	0.0746	zresid2(t-1)
	AR1_2_3	0.34401	0.09175	3.75	0.0002	zresid3(t-1)
zresid3	AR1_3_1	0.21505	0.08552	2.51	0.0128	zresid1(t-1)
	AR1_3_2	0.02319	0.10058	0.23	0.8179	zresid2(t-1)
	AR1_3_3	0.53259	0.08987	5.93	0.0001	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.55476	0.07411	7.49	0.0001	zresid1(t-1)
	AR1_1_2	0.00000	0.00000			zresid2(t-1)
	AR1_1_3	0.39556	0.09102	4.35	0.0001	zresid3(t-1)
zresid2	AR1_2_1	0.29806	0.07110	4.19	0.0001	zresid1(t-1)
	AR1_2_2	0.00000	0.00000			zresid2(t-1)
	AR1_2_3	0.39451	0.08733	4.52	0.0001	zresid3(t-1)
zresid3	AR1_3_1	0.22650	0.06965	3.25	0.0014	zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.53895	0.08554	6.30	0.0001	zresid3(t-1)

Lampiran 5. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 5 (lanjutan)

2017 614		The SAS System 09:32 Thursday, December 19,			
The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.460257	0.068007	6.77	<.0001
w1	1	0.535817	0.090816	5.90	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.248292	0.077076	3.22	0.0015
w2	1	0.479833	0.072188	6.65	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.480374	0.073740	6.51	<.0001
w3	1	0.309713	0.071309	4.34	<.0001

Lampiran 6. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 6

2017 619

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.212823	0.002934	72.53	<.0001
S1	1	22.11260	0.577682	38.28	<.0001
S2	1	23.91722	0.578955	41.31	<.0001
S3	1	27.08944	0.580240	46.69	<.0001
S4	1	23.69401	0.581537	40.74	<.0001
S5	1	22.23722	0.582846	38.15	<.0001
S6	1	17.01268	0.590940	28.79	<.0001
S7	1	13.17020	0.606223	21.72	<.0001
S8	1	10.08650	0.607817	16.59	<.0001
S9	1	6.560262	0.615209	10.66	<.0001
S10	1	9.980430	0.628676	15.88	<.0001
S11	1	13.20825	0.623310	21.19	<.0001
S12	1	17.10769	0.604257	28.31	<.0001
V1t	1	31.73980	1.217151	26.08	<.0001
V2t	1	41.92134	1.054741	39.75	<.0001
V3t	1	47.80465	1.051569	45.46	<.0001
V4t	1	50.20564	1.054451	47.61	<.0001
V1t1	1	49.51438	1.220579	40.57	<.0001
V2t1	1	44.94862	1.054649	42.62	<.0001
V3t1	1	39.55387	1.051563	37.61	<.0001
V4t1	1	34.83074	1.051537	33.12	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.234192	0.002353	99.55	<.0001
S1	1	24.81020	0.463141	53.57	<.0001
S2	1	27.85074	0.464162	60.00	<.0001
S3	1	29.67377	0.465192	63.79	<.0001
S4	1	27.95601	0.466232	59.96	<.0001
S5	1	24.92313	0.467281	53.34	<.0001
S6	1	20.91338	0.473771	44.14	<.0001
S7	1	16.02169	0.486024	32.96	<.0001
S8	1	13.26491	0.487302	27.22	<.0001
S9	1	9.190658	0.493228	18.63	<.0001
S10	1	12.52310	0.504025	24.85	<.0001
S11	1	16.07905	0.499723	32.18	<.0001
S12	1	20.99680	0.484447	43.34	<.0001
V1t	1	44.74274	0.975819	45.85	<.0001
V2t	1	48.04702	0.845611	56.82	<.0001
V3t	1	54.93474	0.843068	65.16	<.0001
V4t	1	58.18927	0.845379	68.83	<.0001
V1t1	1	60.47143	0.978568	61.80	<.0001
V2t1	1	53.03775	0.845537	62.73	<.0001
V3t1	1	43.84438	0.843064	52.01	<.0001
V4t1	1	36.61550	0.843042	43.43	<.0001

Lampiran 6. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 6 (lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.243450	0.002519	96.65	<.0001
S1	1	16.84210	0.495907	33.96	<.0001
S2	1	20.90716	0.497000	42.07	<.0001
S3	1	23.93717	0.498103	48.06	<.0001
S4	1	21.12544	0.499217	42.32	<.0001
S5	1	16.91263	0.500340	33.80	<.0001
S6	1	11.60175	0.507289	22.87	<.0001
S7	1	9.255781	0.520409	17.79	<.0001
S8	1	6.344879	0.521777	12.16	<.0001
S9	1	3.914440	0.528123	7.41	<.0001
S10	1	6.127087	0.539683	11.35	<.0001
S11	1	8.886815	0.535077	16.61	<.0001
S12	1	11.54142	0.518721	22.25	<.0001
V1t	1	37.30638	1.044856	35.70	<.0001
V2t	1	38.56652	0.905436	42.59	<.0001
V3t	1	47.83164	0.902713	52.99	<.0001
V4t	1	50.89516	0.905188	56.23	<.0001
V1t1	1	49.28596	1.047799	47.04	<.0001
V2t1	1	45.89683	0.905357	50.69	<.0001
V3t1	1	41.23589	0.902708	45.68	<.0001
V4t1	1	37.58633	0.902686	41.64	<.0001

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.49735	0.09982	4.98	0.0001	zresid1(t-1)
	AR1_1_2	0.17119	0.09593	1.78	0.0761	zresid2(t-1)
	AR1_1_3	0.30431	0.10414	2.92	0.0039	zresid3(t-1)
zresid2	AR1_2_1	0.21851	0.10423	2.10	0.0375	zresid1(t-1)
	AR1_2_2	0.30661	0.10017	3.06	0.0026	zresid2(t-1)
	AR1_2_3	0.19057	0.10874	1.75	0.0814	zresid3(t-1)
zresid3	AR1_3_1	0.28213	0.10149	2.78	0.0060	zresid1(t-1)
	AR1_3_2	0.12387	0.09754	1.27	0.2058	zresid2(t-1)
	AR1_3_3	0.38520	0.10589	3.64	0.0004	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.68569	0.07149	9.59	0.0001	zresid1(t-1)
	AR1_1_2	0.00000	0.00000			zresid2(t-1)
	AR1_1_3	0.21219	0.07767	2.73	0.0069	zresid3(t-1)
zresid2	AR1_2_1	0.42904	0.06444	6.66	0.0001	zresid1(t-1)
	AR1_2_2	0.21383	0.07285	2.94	0.0038	zresid2(t-1)
	AR1_2_3	0.00000	0.00000			zresid3(t-1)
zresid3	AR1_3_1	0.43643	0.07654	5.70	0.0001	zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.29517	0.08487	3.48	0.0006	zresid3(t-1)

Lampiran 6. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 6 (lanjutan)

The SAS System 09:32 Thursday, December 19,					
2017 673					
The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.457475	0.067727	6.75	<.0001
w1	1	0.531058	0.087233	6.09	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.379230	0.076151	4.98	<.0001
w2	1	0.350790	0.069930	5.02	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.369781	0.073979	5.00	<.0001
w3	1	0.441256	0.075837	5.82	<.0001

Lampiran 7. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 7

2017 678

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.209878	0.002284	91.90	<.0001
S1	1	21.92265	0.449586	48.76	<.0001
S2	1	24.21405	0.450577	53.74	<.0001
S3	1	27.25550	0.451577	60.36	<.0001
S4	1	24.16979	0.452586	53.40	<.0001
S5	1	22.15272	0.453605	48.84	<.0001
S6	1	16.82997	0.459905	36.59	<.0001
S7	1	13.51772	0.471799	28.65	<.0001
S8	1	10.70214	0.473039	22.62	<.0001
S9	1	6.703298	0.478792	14.00	<.0001
S10	1	10.83893	0.489273	22.15	<.0001
S11	1	13.20739	0.485097	27.23	<.0001
S12	1	17.01757	0.470269	36.19	<.0001
V1t	1	32.27978	0.947259	34.08	<.0001
V2t	1	42.59775	0.820861	51.89	<.0001
V3t	1	46.46629	0.818393	56.78	<.0001
V4t	1	47.81762	0.820636	58.27	<.0001
V1t1	1	50.71200	0.949927	53.39	<.0001
V2t1	1	45.65036	0.820790	55.62	<.0001
V3t1	1	37.92199	0.818389	46.34	<.0001
V4t1	1	33.43809	0.818368	40.86	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.230625	0.001695	136.05	<.0001
S1	1	24.97179	0.333726	74.83	<.0001
S2	1	27.86503	0.334461	83.31	<.0001
S3	1	30.35804	0.335203	90.57	<.0001
S4	1	28.18434	0.335953	83.89	<.0001
S5	1	24.85610	0.336709	73.82	<.0001
S6	1	20.81697	0.341385	60.98	<.0001
S7	1	16.23342	0.350214	46.35	<.0001
S8	1	13.60811	0.351135	38.75	<.0001
S9	1	9.460241	0.355405	26.62	<.0001
S10	1	13.39902	0.363185	36.89	<.0001
S11	1	15.74219	0.360085	43.72	<.0001
S12	1	20.96313	0.349078	60.05	<.0001
V1t	1	45.13115	0.703146	64.18	<.0001
V2t	1	48.88781	0.609322	80.23	<.0001
V3t	1	53.94432	0.607489	88.80	<.0001
V4t	1	55.75215	0.609155	91.52	<.0001
V1t1	1	60.36573	0.705127	85.61	<.0001
V2t1	1	54.24647	0.609269	89.04	<.0001
V3t1	1	43.28591	0.607486	71.25	<.0001
V4t1	1	35.29844	0.607471	58.11	<.0001

Lampiran 7. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 7 (lanjutan)

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.239966	0.001901	126.25	<.0001	
S1	1	17.03267	0.374189	45.52	<.0001	
S2	1	21.02783	0.375014	56.07	<.0001	
S3	1	24.22450	0.375846	64.45	<.0001	
S4	1	21.38182	0.376686	56.76	<.0001	
S5	1	17.01525	0.377534	45.07	<.0001	
S6	1	12.07861	0.382778	31.56	<.0001	
S7	1	9.299501	0.392677	23.68	<.0001	
S8	1	6.451807	0.393710	16.39	<.0001	
S9	1	4.642846	0.398498	11.65	<.0001	
S10	1	6.548127	0.407221	16.08	<.0001	
S11	1	9.257291	0.403745	22.93	<.0001	
S12	1	12.09776	0.391404	30.91	<.0001	
V1t	1	36.87130	0.788402	46.77	<.0001	
V2t	1	39.05751	0.683201	57.17	<.0001	
V3t	1	46.40422	0.681147	68.13	<.0001	
V4t	1	50.36761	0.683014	73.74	<.0001	
V1t1	1	49.85865	0.790622	63.06	<.0001	
V2t1	1	46.26371	0.683142	67.72	<.0001	
V3t1	1	39.80345	0.681143	58.44	<.0001	
V4t1	1	36.56079	0.681126	53.68	<.0001	

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.47526	0.09742	4.88	0.0001	zresid1(t-1)
	AR1_1_2	0.15437	0.11999	1.29	0.2000	zresid2(t-1)
	AR1_1_3	0.23476	0.10278	2.28	0.0236	zresid3(t-1)
zresid2	AR1_2_1	0.16085	0.08827	1.82	0.0701	zresid1(t-1)
	AR1_2_2	0.20349	0.10872	1.87	0.0629	zresid2(t-1)
	AR1_2_3	0.17063	0.09312	1.83	0.0686	zresid3(t-1)
zresid3	AR1_3_1	0.09649	0.09268	1.04	0.2993	zresid1(t-1)
	AR1_3_2	0.20633	0.11416	1.81	0.0724	zresid2(t-1)
	AR1_3_3	0.38454	0.09778	3.93	0.0001	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.37228	0.05669	6.57	0.0001	zresid1(t-1)
	AR1_1_2	0.00000	0.00000			zresid2(t-1)
	AR1_1_3	0.43253	0.08125	5.32	0.0001	zresid3(t-1)
zresid2	AR1_2_1	0.00000	0.00000			zresid1(t-1)
	AR1_2_2	0.13572	0.06554	2.07	0.0398	zresid2(t-1)
	AR1_2_3	0.36631	0.07010	5.23	0.0001	zresid3(t-1)
zresid3	AR1_3_1	0.00000	0.00000			zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.61016	0.05829	10.47	0.0001	zresid3(t-1)

Lampiran 7. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 7 (lanjutan)

2017 732		The SAS System 09:32 Thursday, December 19,			
The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.492834	0.068792	7.16	<.0001
w1	1	0.370593	0.096550	3.84	0.0002
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.209754	0.077185	2.72	0.0072
w2	1	0.325447	0.070629	4.61	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.358035	0.075747	4.73	<.0001
w3	1	0.309055	0.079478	3.89	0.0001

Lampiran 8. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 8

The SAS System 09:32 Thursday, December 19,					
2017 737					
The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.217607	0.002241	97.12	<.0001
S1	1	21.33018	0.441089	48.36	<.0001
S2	1	23.63625	0.442061	53.47	<.0001
S3	1	26.48273	0.443043	59.77	<.0001
S4	1	23.23567	0.444033	52.33	<.0001
S5	1	21.16717	0.445032	47.56	<.0001
S6	1	16.42748	0.451213	36.41	<.0001
S7	1	11.96572	0.462882	25.85	<.0001
S8	1	9.451712	0.464100	20.37	<.0001
S9	1	5.434088	0.469744	11.57	<.0001
S10	1	9.403722	0.480026	19.59	<.0001
S11	1	12.13220	0.475929	25.49	<.0001
S12	1	15.90112	0.461381	34.46	<.0001
V1t	1	30.57627	0.929357	32.90	<.0001
V2t	1	42.78919	0.805348	53.13	<.0001
V3t	1	48.03337	0.802926	59.82	<.0001
V4t	1	48.90126	0.805127	60.74	<.0001
V1t1	1	48.35871	0.931975	51.89	<.0001
V2t1	1	45.73183	0.805278	56.79	<.0001
V3t1	1	38.72007	0.802922	48.22	<.0001
V4t1	1	34.36846	0.802902	42.81	<.0001

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.235624	0.001755	134.24	<.0001
S1	1	24.80133	0.345543	71.77	<.0001
S2	1	27.69633	0.346304	79.98	<.0001
S3	1	29.87285	0.347073	86.07	<.0001
S4	1	27.85870	0.347849	80.09	<.0001
S5	1	24.76790	0.348632	71.04	<.0001
S6	1	20.62263	0.353473	58.34	<.0001
S7	1	15.51568	0.362615	42.79	<.0001
S8	1	12.48306	0.363569	34.33	<.0001
S9	1	8.314002	0.367990	22.59	<.0001
S10	1	12.49787	0.376045	33.23	<.0001
S11	1	15.08915	0.372836	40.47	<.0001
S12	1	20.22899	0.361439	55.97	<.0001
V1t	1	43.66744	0.728044	59.98	<.0001
V2t	1	49.47862	0.630898	78.43	<.0001
V3t	1	55.65768	0.629000	88.49	<.0001
V4t	1	56.33869	0.630725	89.32	<.0001
V1t1	1	58.96114	0.730095	80.76	<.0001
V2t1	1	53.89407	0.630843	85.43	<.0001
V3t1	1	44.24775	0.628997	70.35	<.0001
V4t1	1	35.94889	0.628981	57.15	<.0001

Lampiran 8. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 8 (lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.246913	0.002049	120.51	<.0001
S1	1	16.35465	0.403377	40.54	<.0001
S2	1	20.41353	0.404266	50.50	<.0001
S3	1	23.66712	0.405163	58.41	<.0001
S4	1	20.59370	0.406069	50.71	<.0001
S5	1	16.62850	0.406983	40.86	<.0001
S6	1	11.43202	0.412635	27.70	<.0001
S7	1	7.904436	0.423307	18.67	<.0001
S8	1	5.429456	0.424420	12.79	<.0001
S9	1	2.981621	0.429582	6.94	<.0001
S10	1	5.177381	0.438985	11.79	<.0001
S11	1	8.209849	0.435238	18.86	<.0001
S12	1	11.55235	0.421934	27.38	<.0001
V1t	1	35.66159	0.849899	41.96	<.0001
V2t	1	40.29376	0.736493	54.71	<.0001
V3t	1	47.24600	0.734278	64.34	<.0001
V4t	1	51.55105	0.736291	70.01	<.0001
V1t1	1	47.80380	0.852293	56.09	<.0001
V2t1	1	46.84219	0.736429	63.61	<.0001
V3t1	1	41.04455	0.734274	55.90	<.0001
V4t1	1	37.57375	0.734256	51.17	<.0001

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.62894	0.09974	6.31	0.0001	zresid1(t-1)
	AR1_1_2	0.06819	0.11304	0.60	0.5471	zresid2(t-1)
	AR1_1_3	0.09482	0.08847	1.07	0.2853	zresid3(t-1)
zresid2	AR1_2_1	0.39275	0.08802	4.46	0.0001	zresid1(t-1)
	AR1_2_2	0.21969	0.09975	2.20	0.0289	zresid2(t-1)
	AR1_2_3	-0.03536	0.07807	-0.45	0.6512	zresid3(t-1)
zresid3	AR1_3_1	0.48617	0.10231	4.75	0.0001	zresid1(t-1)
	AR1_3_2	-0.11606	0.11595	-1.00	0.3182	zresid2(t-1)
	AR1_3_3	0.25112	0.09074	2.77	0.0063	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.73968	0.05030	14.70	0.0001	zresid1(t-1)
	AR1_1_2	0.00000	0.00000			zresid2(t-1)
	AR1_1_3	0.00000	0.00000			zresid3(t-1)
zresid2	AR1_2_1	0.38963	0.06379	6.11	0.0001	zresid1(t-1)
	AR1_2_2	0.18542	0.07165	2.59	0.0105	zresid2(t-1)
	AR1_2_3	0.00000	0.00000			zresid3(t-1)
zresid3	AR1_3_1	0.44986	0.07205	6.24	0.0001	zresid1(t-1)
	AR1_3_2	0.00000	0.00000			zresid2(t-1)
	AR1_3_3	0.19759	0.07102	2.78	0.0060	zresid3(t-1)

Lampiran 8. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 8 (lanjutan)

The SAS System 09:32 Thursday, December 19, 2017 791					
The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.395398	0.073630	5.37	<.0001
w1	1	0.453230	0.096273	4.71	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.381151	0.075043	5.08	<.0001
w2	1	0.257500	0.068725	3.75	0.0002
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.377418	0.076649	4.92	<.0001
w3	1	0.330741	0.084929	3.89	0.0001

Lampiran 9. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 9

2017 796

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.202606	0.002344	86.45	<.0001
S1	1	22.95382	0.461401	49.75	<.0001
S2	1	24.40995	0.462418	52.79	<.0001
S3	1	27.45270	0.463444	59.24	<.0001
S4	1	24.51091	0.464480	52.77	<.0001
S5	1	22.63602	0.465525	48.62	<.0001
S6	1	18.08551	0.471991	38.32	<.0001
S7	1	14.04126	0.484197	29.00	<.0001
S8	1	11.11991	0.485471	22.91	<.0001
S9	1	7.064954	0.491375	14.38	<.0001
S10	1	11.43683	0.502131	22.78	<.0001
S11	1	14.58650	0.497845	29.30	<.0001
S12	1	18.61268	0.482627	38.57	<.0001
V1t	1	31.12396	0.972152	32.02	<.0001
V2t	1	43.05730	0.842433	51.11	<.0001
V3t	1	46.30600	0.839900	55.13	<.0001
V4t	1	48.53012	0.842202	57.62	<.0001
V1t1	1	49.70582	0.974890	50.99	<.0001
V2t1	1	46.30975	0.842360	54.98	<.0001
V3t1	1	38.67468	0.839895	46.05	<.0001
V4t1	1	33.45141	0.839874	39.83	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.223758	0.001863	120.12	<.0001
S1	1	25.49666	0.366720	69.53	<.0001
S2	1	28.26300	0.367528	76.90	<.0001
S3	1	30.27028	0.368344	82.18	<.0001
S4	1	28.43612	0.369167	77.03	<.0001
S5	1	25.82043	0.369998	69.79	<.0001
S6	1	21.65783	0.375137	57.73	<.0001
S7	1	16.91578	0.384838	43.96	<.0001
S8	1	13.64675	0.385850	35.37	<.0001
S9	1	9.855331	0.390543	25.23	<.0001
S10	1	14.00618	0.399092	35.10	<.0001
S11	1	17.60769	0.395685	44.50	<.0001
S12	1	22.04471	0.383590	57.47	<.0001
V1t	1	44.98963	0.772663	58.23	<.0001
V2t	1	49.24839	0.669563	73.55	<.0001
V3t	1	54.80896	0.667549	82.10	<.0001
V4t	1	56.71896	0.669379	84.73	<.0001
V1t1	1	59.60631	0.774840	76.93	<.0001
V2t1	1	54.31239	0.669505	81.12	<.0001
V3t1	1	43.81377	0.667546	65.63	<.0001
V4t1	1	35.32770	0.667529	52.92	<.0001

Lampiran 9. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 9 (lanjutan)

Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.233186	0.002050	113.77	<.0001	
S1	1	17.71983	0.403510	43.91	<.0001	
S2	1	21.40966	0.404400	52.94	<.0001	
S3	1	24.13569	0.405297	59.55	<.0001	
S4	1	21.27226	0.406203	52.37	<.0001	
S5	1	17.04529	0.407117	41.87	<.0001	
S6	1	12.37829	0.412771	29.99	<.0001	
S7	1	9.658489	0.423447	22.81	<.0001	
S8	1	6.802990	0.424560	16.02	<.0001	
S9	1	4.483731	0.429723	10.43	<.0001	
S10	1	6.863618	0.439130	15.63	<.0001	
S11	1	10.27988	0.435382	23.61	<.0001	
S12	1	13.50994	0.422073	32.01	<.0001	
V1t	1	36.80032	0.850180	43.29	<.0001	
V2t	1	40.61170	0.736736	55.12	<.0001	
V3t	1	46.80262	0.734520	63.72	<.0001	
V4t	1	51.22623	0.736534	69.55	<.0001	
V1t1	1	48.67762	0.852574	57.09	<.0001	
V2t1	1	47.52583	0.736671	64.51	<.0001	
V3t1	1	40.81642	0.734517	55.57	<.0001	
V4t1	1	36.78807	0.734498	50.09	<.0001	

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.25996	0.09103	2.86	0.0048	zresid1(t-1)
	AR1_1_2	0.35990	0.09455	3.81	0.0002	zresid2(t-1)
	AR1_1_3	0.35169	0.09358	3.76	0.0002	zresid3(t-1)
zresid2	AR1_2_1	-0.10743	0.09152	-1.17	0.2420	zresid1(t-1)
	AR1_2_2	0.52383	0.09506	5.51	0.0001	zresid2(t-1)
	AR1_2_3	0.25127	0.09408	2.67	0.0083	zresid3(t-1)
zresid3	AR1_3_1	0.06678	0.08941	0.75	0.4561	zresid1(t-1)
	AR1_3_2	0.19710	0.09287	2.12	0.0352	zresid2(t-1)
	AR1_3_3	0.52572	0.09192	5.72	0.0001	zresid3(t-1)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.28291	0.06421	4.41	0.0001	zresid1(t-1)
	AR1_1_2	0.34843	0.08889	3.92	0.0001	zresid2(t-1)
	AR1_1_3	0.33767	0.08487	3.98	0.0001	zresid3(t-1)
zresid2	AR1_2_1	0.00000	0.00000			zresid1(t-1)
	AR1_2_2	0.47017	0.08335	5.64	0.0001	zresid2(t-1)
	AR1_2_3	0.18564	0.07567	2.45	0.0151	zresid3(t-1)
zresid3	AR1_3_1	0.00000	0.00000			zresid1(t-1)
	AR1_3_2	0.23046	0.08143	2.83	0.0052	zresid2(t-1)
	AR1_3_3	0.56652	0.07392	7.66	0.0001	zresid3(t-1)

Lampiran 9. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 9 (lanjutan)

2017 850

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.372071	0.067779	5.49	<.0001
w1	1	0.570985	0.089394	6.39	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.458747	0.074394	6.17	<.0001
w2	1	0.167516	0.069370	2.41	0.0168

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.455789	0.071671	6.36	<.0001
w3	1	0.313218	0.076366	4.10	<.0001

Lampiran 10. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 10

2017 855

The SAS System 09:32 Thursday, December 19,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.213273	0.002751	77.53	<.0001
S1	1	21.09352	0.541572	38.95	<.0001
S2	1	23.68899	0.542765	43.64	<.0001
S3	1	26.43419	0.543970	48.59	<.0001
S4	1	23.60224	0.545186	43.29	<.0001
S5	1	21.29844	0.546413	38.98	<.0001
S6	1	16.32712	0.554002	29.47	<.0001
S7	1	12.51881	0.568329	22.03	<.0001
S8	1	9.108915	0.569824	15.99	<.0001
S9	1	5.157219	0.576754	8.94	<.0001
S10	1	9.017814	0.589379	15.30	<.0001
S11	1	11.82562	0.584348	20.24	<.0001
S12	1	16.26764	0.566486	28.72	<.0001
V1t	1	33.22246	1.141070	29.12	<.0001
V2t	1	44.79594	0.988811	45.30	<.0001
V3t	1	45.63999	0.985837	46.30	<.0001
V4t	1	48.03161	0.988540	48.59	<.0001
V1t1	1	51.82506	1.144284	45.29	<.0001
V2t1	1	47.01367	0.988725	47.55	<.0001
V3t1	1	37.34133	0.985832	37.88	<.0001
V4t1	1	33.41939	0.985807	33.90	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.234826	0.002223	105.62	<.0001
S1	1	24.01788	0.437691	54.87	<.0001
S2	1	27.60477	0.438656	62.93	<.0001
S3	1	29.24769	0.439629	66.53	<.0001
S4	1	27.63722	0.440612	62.72	<.0001
S5	1	24.21613	0.441604	54.84	<.0001
S6	1	20.15216	0.447737	45.01	<.0001
S7	1	14.99017	0.459316	32.64	<.0001
S8	1	11.81158	0.460524	25.65	<.0001
S9	1	7.919525	0.466125	16.99	<.0001
S10	1	12.01614	0.476328	25.23	<.0001
S11	1	14.76653	0.472263	31.27	<.0001
S12	1	19.99579	0.457827	43.68	<.0001
V1t	1	46.18372	0.922198	50.08	<.0001
V2t	1	51.38369	0.799144	64.30	<.0001
V3t	1	54.41139	0.796741	68.29	<.0001
V4t	1	56.87467	0.798925	71.19	<.0001
V1t1	1	62.05368	0.924795	67.10	<.0001
V2t1	1	54.25739	0.799074	67.90	<.0001
V3t1	1	43.05855	0.796737	54.04	<.0001
V4t1	1	35.73248	0.796717	44.85	<.0001

Lampiran 10. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 10
(lanjutan)

Parameter Estimates							
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
	t	1	0.244884	0.002387	102.58	<.0001	
	S1	1	16.09226	0.469971	34.24	<.0001	
	S2	1	20.76474	0.471007	44.09	<.0001	
	S3	1	23.49419	0.472052	49.77	<.0001	
	S4	1	20.43547	0.473108	43.19	<.0001	
	S5	1	16.03210	0.474172	33.81	<.0001	
	S6	1	11.13075	0.480758	23.15	<.0001	
	S7	1	8.367704	0.493191	16.97	<.0001	
	S8	1	5.355007	0.494488	10.83	<.0001	
	S9	1	3.234813	0.500502	6.46	<.0001	
	S10	1	4.886087	0.511458	9.55	<.0001	
	S11	1	7.528874	0.507092	14.85	<.0001	
	S12	1	11.14013	0.491592	22.66	<.0001	
	V1t	1	38.50841	0.990210	38.89	<.0001	
	V2t	1	41.55837	0.858081	48.43	<.0001	
	V3t	1	46.02839	0.855501	53.80	<.0001	
	V4t	1	50.24207	0.857846	58.57	<.0001	
	V1t1	1	51.07072	0.992999	51.43	<.0001	
	V2t1	1	47.65516	0.858007	55.54	<.0001	
	V3t1	1	39.89512	0.855497	46.63	<.0001	
	V4t1	1	36.20204	0.855475	42.32	<.0001	
Model Parameter Estimates							
Equation	Parameter		Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1		0.33944	0.09702	3.50	0.0006	zresid1(t-1)
	AR1_1_2		0.29779	0.10252	2.90	0.0041	zresid2(t-1)
	AR1_1_3		0.33568	0.09890	3.39	0.0009	zresid3(t-1)
zresid2	AR1_2_1		0.13753	0.09206	1.49	0.1370	zresid1(t-1)
	AR1_2_2		0.46332	0.09728	4.76	0.0001	zresid2(t-1)
	AR1_2_3		0.13661	0.09385	1.46	0.1473	zresid3(t-1)
zresid3	AR1_3_1		0.16649	0.08938	1.86	0.0642	zresid1(t-1)
	AR1_3_2		0.17626	0.09444	1.87	0.0637	zresid2(t-1)
	AR1_3_3		0.48096	0.09111	5.28	0.0001	zresid3(t-1)
Model Parameter Estimates							
Equation	Parameter		Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1		0.20973	0.06839	3.07	0.0025	zresid1(t-1)
	AR1_1_2		0.49391	0.08427	5.86	0.0001	zresid2(t-1)
	AR1_1_3		0.26457	0.07391	3.58	0.0004	zresid3(t-1)
zresid2	AR1_2_1		0.00000	0.00000			zresid1(t-1)
	AR1_2_2		0.72353	0.05078	14.25	0.0001	zresid2(t-1)
	AR1_2_3		0.00000	0.00000			zresid3(t-1)
zresid3	AR1_3_1		0.00000	0.00000			zresid1(t-1)
	AR1_3_2		0.36469	0.07294	5.00	0.0001	zresid2(t-1)
	AR1_3_3		0.46383	0.06296	7.37	0.0001	zresid3(t-1)

Lampiran 10. Output SAS Pemodelan VARX dan GSTARX Skenario I Data Simulasi 10
(lanjutan)

2017 909		The SAS System 09:32 Thursday, December 19,			
The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi1	1	0.341202	0.071669	4.76	<.0001
w1	1	0.632937	0.092209	6.86	<.0001
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi2	1	0.473288	0.074147	6.38	<.0001
w2	1	0.265826	0.068971	3.85	0.0002
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi3	1	0.470498	0.071541	6.58	<.0001
w3	1	0.351505	0.073615	4.77	<.0001

Lampiran 11. Contoh Syntax SAS Model VARX(1) dan GSTARX(1₁) Bobot Seragam

```

data simulasi;
input Z1 Z2 Z3 t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
      V3t1 V4t1;
datalines;
21.86788576 25.66443467 16.00463076 1 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
23.41949187 27.39277081 19.93943328 2 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
25.66968085 29.20282176 23.82011194 3 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
.
.
.
47.1237955 55.85856704 51.19526231 179 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
52.75963176 60.45156365 53.59882508 180 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
;

proc syslin data=simulasi out=resiTSR sur;
  Z1:  model Z1 = t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
        V3t1 V4t1 / noint;
        output p=zhat1 r=zresid1;
  Z2:  model Z2 = t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
        V3t1 V4t1 / noint;
        output p=zhat2 r=zresid2;
  Z3:  model Z3 = t S1 S2 S3 S4 S5 S6 S7 S8 S9 S10 S11 S12 V1t V2t V3t V4t V1t1 V2t1
        V3t1 V4t1 / noint;
        output p=zhat3 r=zresid3;
run;

proc varmax data=resiTSR printall;
  model zresid1 zresid2 zresid3/ p=1 noint minic= (p=3 q=3);
  restrict AR(1,1,3)=0, AR(1,2,1)=0, AR(1,2,3)=0, AR(1,3,1)=0;
  output lead=12 out=hasilVARX;
run;

proc export data=work.hasilVARX
  outfile='D:\VARXskenario1simul1.xls'
  dbms=excel
  replace;
run;

data resiTSR;
  set resiTSR;
  lagresi1 = lag(zresid1);
  lagresi2 = lag(zresid2);
  lagresi3 = lag(zresid3);
  w1= .5*(lagresi2+lagresi3);
  w2= .5*(lagresi1+lagresi3);
  w3= .5*(lagresi1+lagresi2);
proc print data=resiTSR;
run;

proc syslin data=resiTSR sur out=HASILGSTARX;
  e1t:  model zresid1= lagresi1 w1/ noint;
        output p=ehat1 r=eresid1;
  e2t:  model zresid2= lagresi2 w2/ noint;
        output p=ehat2 r=eresid2;
  e3t:  model zresid3= lagresi3 w3/ noint;
        output p=ehat3 r=eresid3;
run;

proc export data=work.HASILGSTARX
  outfile='D:\GSTARXskenario1simul1.xls'
  dbms=excel
  replace;
run;

```

Lampiran 12. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 2 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,003	0,950	1,016	1,384	1,378	1,181
GSTARX-FFNN (6,2,1)	0,978	0,939	0,990	1,366	1,397	1,178
GSTARX-FFNN (6,3,1)	0,938	0,940	0,992	1,359	1,414	1,150
GSTARX-FFNN (6,4,1)	0,955	0,928	0,998	1,335	1,384	1,205
GSTARX-FFNN (6,5,1)*	0,931	0,948	1,001	1,380	1,318	1,134
GSTARX-FFNN (6,10,1)	0,933	0,968	1,001	1,368	1,318	1,214
GSTARX-FFNN (6,15,1)	0,951	0,956	1,018	1,404	1,329	1,215

Lampiran 12. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 2 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,011	0,941	0,995	1,391	1,478	1,123
GSTARX-DLNN (6,1,2,1)	1,062	0,964	1,074	1,369	1,423	1,114
GSTARX-DLNN (6,1,3,1)	1,036	0,930	1,003	1,387	1,455	1,099
GSTARX-DLNN (6,1,4,1)	0,977	0,937	0,991	1,403	1,413	1,168
GSTARX-DLNN (6,1,5,1)	0,979	0,965	1,057	1,383	1,356	1,270
GSTARX-DLNN (6,2,1,1)	1,005	0,957	1,009	1,312	1,409	1,147
GSTARX-DLNN (6,2,2,1)	0,980	0,938	1,008	1,362	1,346	1,125
GSTARX-DLNN (6,2,3,1)	0,990	0,957	1,026	1,364	1,413	1,129
GSTARX-DLNN (6,2,4,1)	0,962	0,927	0,996	1,361	1,436	1,110
GSTARX-DLNN (6,2,5,1)	0,929	0,924	0,988	1,397	1,379	1,138
GSTARX-DLNN (6,3,1,1)	1,010	0,943	1,004	1,328	1,491	1,117
GSTARX-DLNN (6,3,2,1)*	0,925	0,921	0,986	1,380	1,329	1,164
GSTARX-DLNN (6,3,3,1)	0,996	0,945	0,994	1,275	1,388	1,140
GSTARX-DLNN (6,3,4,1)	0,991	0,960	1,000	1,360	1,320	1,160
GSTARX-DLNN (6,3,5,1)	0,956	0,944	0,997	1,402	1,402	1,125
GSTARX-DLNN (6,4,1,1)	0,967	0,924	0,997	1,386	1,403	1,168
GSTARX-DLNN (6,4,2,1)	0,951	0,932	0,993	1,358	1,353	1,171
GSTARX-DLNN (6,4,3,1)	0,972	0,941	0,996	1,358	1,368	1,138
GSTARX-DLNN (6,4,4,1)	0,971	0,930	0,992	1,382	1,362	1,151
GSTARX-DLNN (6,4,5,1)	1,012	0,975	1,058	1,315	1,338	1,164
GSTARX-DLNN (6,5,1,1)	0,980	0,942	0,994	1,369	1,445	1,119
GSTARX-DLNN (6,5,2,1)	0,965	0,928	0,991	1,378	1,371	1,147
GSTARX-DLNN (6,5,3,1)	0,968	0,923	0,991	1,336	1,389	1,149
GSTARX-DLNN (6,5,4,1)	0,978	0,964	1,009	1,342	1,457	1,138
GSTARX-DLNN (6,5,5,1)	0,983	0,924	0,999	1,317	1,402	1,127
GSTARX-DLNN (6,10,1,1)	1,013	0,929	1,005	1,378	1,403	1,121
GSTARX-DLNN (6,10,2,1)	0,981	0,951	1,028	1,351	1,336	1,127
GSTARX-DLNN (6,10,3,1)	0,952	0,924	0,989	1,363	1,354	1,143
GSTARX-DLNN (6,10,4,1)	0,981	0,944	0,996	1,332	1,324	1,149
GSTARX-DLNN (6,10,5,1)	0,972	0,973	0,997	1,366	1,327	1,180
GSTARX-DLNN (6,15,1,1)	0,969	0,949	0,993	1,431	1,307	1,168
GSTARX-DLNN (6,15,2,1)	0,947	0,923	0,988	1,333	1,391	1,144
GSTARX-DLNN (6,15,3,1)	0,989	0,945	1,082	1,293	1,377	1,236
GSTARX-DLNN (6,15,4,1)	0,969	0,945	0,985	1,325	1,339	1,154
GSTARX-DLNN (6,15,5,1)	0,979	0,924	0,990	1,351	1,386	1,179

Ket: *model terbaik

Lampiran 13. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 3 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,071	1,036	0,996	1,145	0,793	1,000
GSTARX-FFNN (6,2,1)	1,111	1,068	1,009	1,147	0,822	0,952
GSTARX-FFNN (6,3,1)	1,061	1,052	0,980	1,150	0,828	0,985
GSTARX-FFNN (6,4,1)	1,046	1,027	0,977	1,136	0,792	1,012
GSTARX-FFNN (6,5,1)	1,048	1,040	0,969	1,174	0,810	0,994
GSTARX-FFNN (6,10,1)	1,042	1,030	0,986	1,179	0,818	0,979
GSTARX-FFNN (6,15,1)*	1,053	1,032	1,020	1,114	0,839	0,931

Lampiran 13. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 3 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSSTARX-DLNN (6,1,1,1)	1,174	1,058	1,052	1,143	0,780	0,948
GSSTARX-DLNN (6,1,2,1)	1,109	1,036	1,041	1,142	0,788	0,960
GSSTARX-DLNN (6,1,3,1)	1,106	1,043	1,016	1,135	0,781	1,011
GSSTARX-DLNN (6,1,4,1)	1,086	1,032	0,989	1,155	0,805	0,982
GSSTARX-DLNN (6,1,5,1)	1,079	1,022	1,004	1,106	0,802	1,005
GSSTARX-DLNN (6,2,1,1)	1,135	1,051	1,010	1,155	0,801	0,965
GSSTARX-DLNN (6,2,2,1)	1,103	1,049	1,014	1,147	0,793	0,981
GSSTARX-DLNN (6,2,3,1)	1,090	1,061	1,004	1,148	0,779	0,918
GSSTARX-DLNN (6,2,4,1)	1,071	1,029	0,991	1,132	0,814	1,019
GSSTARX-DLNN (6,2,5,1)	1,090	1,046	1,026	1,170	0,794	0,952
GSSTARX-DLNN (6,3,1,1)	1,162	1,097	1,072	1,119	0,798	0,960
GSSTARX-DLNN (6,3,2,1)	1,067	1,036	0,991	1,139	0,793	0,970
GSSTARX-DLNN (6,3,3,1)	1,110	1,050	1,047	1,109	0,830	0,969
GSSTARX-DLNN (6,3,4,1)	1,103	1,047	1,008	1,133	0,787	1,029
GSSTARX-DLNN (6,3,5,1)	1,097	1,074	1,065	1,134	0,863	0,921
GSSTARX-DLNN (6,4,1,1)	1,164	1,073	1,008	1,120	0,771	0,966
GSSTARX-DLNN (6,4,2,1)	1,103	1,081	1,030	1,124	0,794	0,923
GSSTARX-DLNN (6,4,3,1)	1,067	1,034	0,973	1,137	0,798	0,965
GSSTARX-DLNN (6,4,4,1)	1,097	1,048	1,030	1,100	0,776	0,966
GSSTARX-DLNN (6,4,5,1)	1,060	1,044	0,993	1,126	0,793	1,016
GSSTARX-DLNN (6,5,1,1)	1,120	1,075	1,026	1,125	0,776	0,954
GSSTARX-DLNN (6,5,2,1)	1,171	1,104	1,136	0,989	0,791	1,035
GSSTARX-DLNN (6,5,3,1)	1,078	1,041	0,989	1,167	0,792	0,965
GSSTARX-DLNN (6,5,4,1)	1,061	1,054	0,990	1,136	0,856	0,956
GSSTARX-DLNN (6,5,5,1)	1,080	1,062	1,011	1,151	0,820	0,948
GSSTARX-DLNN (6,10,1,1)	1,092	1,043	0,980	1,157	0,799	0,987
GSSTARX-DLNN (6,10,2,1)	1,062	1,042	0,994	1,157	0,779	0,972
GSSTARX-DLNN (6,10,3,1)	1,067	1,046	1,027	1,134	0,801	0,982
GSSTARX-DLNN (6,10,4,1)	1,086	1,044	1,024	1,096	0,788	0,971
GSSTARX-DLNN (6,10,5,1)	1,046	1,060	1,021	1,146	0,788	0,996
GSSTARX-DLNN (6,15,1,1)	1,122	1,048	1,027	1,164	0,826	0,942
GSSTARX-DLNN (6,15,2,1)	1,089	1,061	1,007	1,133	0,798	0,937
GSSTARX-DLNN (6,15,3,1)	1,080	1,045	0,979	1,174	0,800	0,970
GSSTARX-DLNN (6,15,4,1)*	1,036	1,021	0,960	1,149	0,795	0,991
GSSTARX-DLNN (6,15,5,1)	1,093	1,077	1,058	1,147	0,830	0,904

Ket: *model terbaik

Lampiran 14. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 4 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	0,930	0,989	1,034	1,365	1,259	1,433
GSTARX-FFNN (6,2,1)	0,932	0,986	1,022	1,325	1,254	1,416
GSTARX-FFNN (6,3,1)	1,012	1,019	1,120	1,343	1,212	1,470
GSTARX-FFNN (6,4,1)	1,041	1,001	1,121	1,196	1,297	1,469
GSTARX-FFNN (6,5,1)	0,931	0,995	1,033	1,314	1,229	1,445
GSTARX-FFNN (6,10,1)*	1,051	1,021	1,087	1,129	1,308	1,401
GSTARX-FFNN (6,15,1)	0,950	1,005	1,061	1,203	1,266	1,483

Lampiran 14. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 4 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	0,935	0,991	1,039	1,435	1,259	1,431
GSTARX-DLNN (6,1,2,1)	1,065	1,053	1,190	1,383	1,253	1,483
GSTARX-DLNN (6,1,3,1)	0,931	0,995	1,039	1,386	1,230	1,441
GSTARX-DLNN (6,1,4,1)	0,927	0,989	1,030	1,347	1,257	1,440
GSTARX-DLNN (6,1,5,1)	0,929	0,990	1,032	1,339	1,249	1,439
GSTARX-DLNN (6,2,1,1)	0,930	0,990	1,034	1,374	1,257	1,441
GSTARX-DLNN (6,2,2,1)	0,937	0,994	1,040	1,411	1,242	1,458
GSTARX-DLNN (6,2,3,1)	0,923	0,988	1,023	1,308	1,247	1,435
GSTARX-DLNN (6,2,4,1)	0,924	0,989	1,022	1,327	1,257	1,431
GSTARX-DLNN (6,2,5,1)	0,923	0,988	1,019	1,316	1,256	1,431
GSTARX-DLNN (6,3,1,1)	0,940	0,993	1,021	1,337	1,236	1,411
GSTARX-DLNN (6,3,2,1)	0,926	0,989	1,024	1,316	1,258	1,425
GSTARX-DLNN (6,3,3,1)	0,928	0,986	1,022	1,304	1,248	1,429
GSTARX-DLNN (6,3,4,1)	0,926	0,987	1,029	1,316	1,231	1,439
GSTARX-DLNN (6,3,5,1)	0,924	0,988	1,018	1,302	1,254	1,435
GSTARX-DLNN (6,4,1,1)	0,931	0,991	1,029	1,361	1,247	1,424
GSTARX-DLNN (6,4,2,1)	0,923	0,988	1,021	1,321	1,222	1,412
GSTARX-DLNN (6,4,3,1)	0,927	0,986	1,004	1,271	1,188	1,409
GSTARX-DLNN (6,4,4,1)	0,924	0,989	1,012	1,301	1,241	1,400
GSTARX-DLNN (6,4,5,1)	0,927	0,987	1,007	1,276	1,245	1,407
GSTARX-DLNN (6,5,1,1)	0,928	0,987	0,998	1,332	1,244	1,401
GSTARX-DLNN (6,5,2,1)	0,929	0,988	1,016	1,308	1,256	1,402
GSTARX-DLNN (6,5,3,1)	0,928	0,993	1,014	1,316	1,230	1,407
GSTARX-DLNN (6,5,4,1)	0,931	0,998	1,016	1,353	1,233	1,373
GSTARX-DLNN (6,5,5,1)	0,923	0,989	1,010	1,271	1,244	1,433
GSTARX-DLNN (6,10,1,1)	0,926	0,987	1,001	1,324	1,250	1,414
GSTARX-DLNN (6,10,2,1)	0,930	0,983	1,009	1,267	1,233	1,425
GSTARX-DLNN (6,10,3,1)	0,931	0,988	1,027	1,236	1,266	1,429
GSTARX-DLNN (6,10,4,1)	0,921	0,987	1,011	1,304	1,234	1,396
GSTARX-DLNN (6,10,5,1)	0,925	0,995	1,019	1,289	1,254	1,430
GSTARX-DLNN (6,15,1,1)	0,925	0,979	0,999	1,336	1,215	1,393
GSTARX-DLNN (6,15,2,1)	0,926	0,986	1,008	1,292	1,222	1,406
GSTARX-DLNN (6,15,3,1)*	0,919	0,980	1,000	1,268	1,199	1,406
GSTARX-DLNN (6,15,4,1)	0,922	0,982	1,009	1,262	1,247	1,415
GSTARX-DLNN (6,15,5,1)	0,927	0,989	1,014	1,319	1,231	1,420

Ket: *model terbaik

Lampiran 15. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 5 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,617	1,484	1,754	0,693	0,957	0,824
GSTARX-FFNN (6,2,1)	1,461	1,194	1,165	0,714	1,008	0,888
GSTARX-FFNN (6,3,1)	1,475	1,137	1,105	0,644	0,976	0,908
GSTARX-FFNN (6,4,1)	1,754	1,256	1,462	0,777	0,952	0,805
GSTARX-FFNN (6,5,1)	1,639	1,197	1,067	0,690	0,954	1,133
GSTARX-FFNN (6,10,1)	1,012	0,962	0,950	0,849	1,054	0,935
GSTARX-FFNN (6,15,1)*	1,012	0,962	0,953	0,840	1,066	0,906

Lampiran 15. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 5 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,713	1,639	1,430	0,728	1,011	0,807
GSTARX-DLNN (6,1,2,1)	1,732	1,388	1,680	0,758	0,959	0,833
GSTARX-DLNN (6,1,3,1)	1,595	1,619	1,275	0,704	0,957	0,826
GSTARX-DLNN (6,1,4,1)	1,541	1,281	1,461	0,737	0,963	0,819
GSTARX-DLNN (6,1,5,1)	1,674	1,233	1,320	0,792	0,957	0,808
GSTARX-DLNN (6,2,1,1)	1,793	1,321	1,395	0,767	0,970	0,805
GSTARX-DLNN (6,2,2,1)	1,626	1,270	1,286	0,718	0,956	0,878
GSTARX-DLNN (6,2,3,1)	1,793	1,583	1,383	0,761	0,968	0,811
GSTARX-DLNN (6,2,4,1)	1,592	1,247	1,450	0,732	0,977	0,801
GSTARX-DLNN (6,2,5,1)	1,695	1,329	1,332	0,737	0,947	0,811
GSTARX-DLNN (6,3,1,1)	1,688	1,368	1,461	0,748	0,959	0,831
GSTARX-DLNN (6,3,2,1)	1,601	1,288	1,454	0,716	0,953	0,833
GSTARX-DLNN (6,3,3,1)	1,564	1,491	1,342	0,759	0,970	0,817
GSTARX-DLNN (6,3,4,1)	1,726	1,498	1,475	0,735	0,948	0,845
GSTARX-DLNN (6,3,5,1)	1,678	1,319	1,210	0,666	0,962	0,921
GSTARX-DLNN (6,4,1,1)	1,740	1,384	1,398	0,741	0,941	0,836
GSTARX-DLNN (6,4,2,1)	1,638	1,429	1,593	0,729	0,968	0,814
GSTARX-DLNN (6,4,3,1)	1,653	1,275	1,651	0,803	0,954	0,823
GSTARX-DLNN (6,4,4,1)*	1,419	1,125	1,065	0,758	0,960	0,948
GSTARX-DLNN (6,4,5,1)	1,601	1,297	1,477	0,711	0,976	0,841
GSTARX-DLNN (6,5,1,1)	1,434	1,252	1,398	0,712	0,995	0,810
GSTARX-DLNN (6,5,2,1)	1,449	1,270	1,603	0,701	0,930	0,840
GSTARX-DLNN (6,5,3,1)	1,579	1,550	1,566	0,758	0,962	0,816
GSTARX-DLNN (6,5,4,1)	1,449	1,474	1,414	0,757	1,001	0,813
GSTARX-DLNN (6,5,5,1)	1,540	1,315	1,509	0,696	0,950	0,801
GSTARX-DLNN (6,10,1,1)	1,629	1,320	1,481	0,742	0,946	0,857
GSTARX-DLNN (6,10,2,1)	1,378	1,079	1,424	0,716	1,015	0,822
GSTARX-DLNN (6,10,3,1)	1,471	1,207	1,298	0,678	0,966	0,881
GSTARX-DLNN (6,10,4,1)	1,758	1,381	1,456	0,818	0,996	0,839
GSTARX-DLNN (6,10,5,1)	1,585	1,518	1,511	0,774	0,966	0,852
GSTARX-DLNN (6,15,1,1)	1,827	1,301	1,383	0,801	0,968	0,816
GSTARX-DLNN (6,15,2,1)	1,697	1,365	1,532	0,762	0,975	0,827
GSTARX-DLNN (6,15,3,1)	1,526	1,353	1,629	0,695	1,016	0,863
GSTARX-DLNN (6,15,4,1)	1,796	1,347	1,261	0,908	0,957	0,856
GSTARX-DLNN (6,15,5,1)	1,640	1,433	1,359	0,698	1,012	0,812

Ket: *model terbaik

Lampiran 16. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 6 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,095	1,062	1,055	1,298	1,124	1,271
GSTARX-FFNN (6,2,1)	1,088	1,064	1,030	1,289	1,069	1,344
GSTARX-FFNN (6,3,1)	1,101	1,117	1,058	1,283	1,068	1,280
GSTARX-FFNN (6,4,1)	1,039	1,058	1,044	1,334	1,100	1,272
GSTARX-FFNN (6,5,1)	1,040	1,109	1,031	1,335	1,040	1,325
GSTARX-FFNN (6,10,1)*	1,111	1,071	1,118	1,279	1,039	1,212
GSTARX-FFNN (6,15,1)	1,061	1,078	1,019	1,347	0,998	1,356

Lampiran 16. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 6 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)*	1,021	1,030	1,025	1,332	1,074	1,282
GSTARX-DLNN (6,1,2,1)	1,195	1,113	1,109	1,329	1,027	1,297
GSTARX-DLNN (6,1,3,1)	1,126	1,059	1,067	1,301	1,055	1,317
GSTARX-DLNN (6,1,4,1)	1,064	1,046	1,038	1,307	1,081	1,292
GSTARX-DLNN (6,1,5,1)	1,047	1,058	1,028	1,330	1,053	1,315
GSTARX-DLNN (6,2,1,1)	1,172	1,094	1,134	1,307	1,020	1,278
GSTARX-DLNN (6,2,2,1)	1,180	1,105	1,088	1,327	0,998	1,359
GSTARX-DLNN (6,2,3,1)	1,067	1,044	1,053	1,317	1,091	1,235
GSTARX-DLNN (6,2,4,1)	1,186	1,193	1,135	1,277	1,022	1,243
GSTARX-DLNN (6,2,5,1)	1,176	1,099	1,120	1,336	1,038	1,185
GSTARX-DLNN (6,3,1,1)	1,104	1,063	1,066	1,308	1,082	1,307
GSTARX-DLNN (6,3,2,1)	1,099	1,071	1,052	1,289	1,037	1,339
GSTARX-DLNN (6,3,3,1)	1,022	1,032	1,031	1,328	1,075	1,313
GSTARX-DLNN (6,3,4,1)	1,115	1,094	1,088	1,283	1,069	1,346
GSTARX-DLNN (6,3,5,1)	1,056	1,052	1,026	1,295	1,059	1,356
GSTARX-DLNN (6,4,1,1)	1,085	1,059	1,055	1,292	1,041	1,302
GSTARX-DLNN (6,4,2,1)	1,069	1,063	1,035	1,308	1,079	1,321
GSTARX-DLNN (6,4,3,1)	1,114	1,057	1,055	1,354	1,107	1,313
GSTARX-DLNN (6,4,4,1)	1,149	1,153	1,139	1,292	1,056	1,285
GSTARX-DLNN (6,4,5,1)	1,153	1,127	1,169	1,325	1,037	1,221
GSTARX-DLNN (6,5,1,1)	1,144	1,086	1,070	1,330	1,046	1,306
GSTARX-DLNN (6,5,2,1)	1,076	1,067	1,032	1,339	1,049	1,294
GSTARX-DLNN (6,5,3,1)	1,060	1,049	1,079	1,306	1,080	1,249
GSTARX-DLNN (6,5,4,1)	1,070	1,075	1,065	1,312	1,063	1,271
GSTARX-DLNN (6,5,5,1)	1,059	1,067	1,041	1,300	1,086	1,321
GSTARX-DLNN (6,10,1,1)	1,051	1,053	1,064	1,308	1,072	1,260
GSTARX-DLNN (6,10,2,1)	1,054	1,054	1,035	1,323	1,092	1,311
GSTARX-DLNN (6,10,3,1)	1,106	1,070	1,122	1,355	1,055	1,202
GSTARX-DLNN (6,10,4,1)	1,028	1,051	1,019	1,332	1,031	1,316
GSTARX-DLNN (6,10,5,1)	1,017	1,050	1,006	1,362	1,064	1,284
GSTARX-DLNN (6,15,1,1)	1,187	1,069	1,061	1,304	1,048	1,351
GSTARX-DLNN (6,15,2,1)	1,018	1,041	1,047	1,327	1,104	1,246
GSTARX-DLNN (6,15,3,1)	1,073	1,099	1,057	1,303	1,097	1,305
GSTARX-DLNN (6,15,4,1)	1,097	1,090	1,098	1,375	1,051	1,257
GSTARX-DLNN (6,15,5,1)	1,225	1,072	1,113	1,336	1,099	1,155

Ket: *model terbaik

Lampiran 17. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 7 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,055	0,917	0,962	0,429	1,126	0,929
GSTARX-FFNN (6,2,1)*	1,053	0,941	0,960	0,358	1,115	0,974
GSTARX-FFNN (6,3,1)	1,022	0,925	0,956	0,411	1,138	0,917
GSTARX-FFNN (6,4,1)	1,005	0,912	0,948	0,426	1,130	0,913
GSTARX-FFNN (6,5,1)	1,033	0,933	0,965	0,396	1,128	0,930
GSTARX-FFNN (6,10,1)	1,017	0,916	0,952	0,441	1,146	0,911
GSTARX-FFNN (6,15,1)	1,005	0,909	0,951	0,450	1,136	0,891

Lampiran 17. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 7 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,051	0,920	0,963	0,433	1,121	0,938
GSTARX-DLNN (6,1,2,1)	1,260	0,992	1,301	0,540	1,056	0,760
GSTARX-DLNN (6,1,3,1)	1,347	1,061	1,163	0,501	1,049	0,854
GSTARX-DLNN (6,1,4,1)	1,090	0,936	0,966	0,453	1,094	0,936
GSTARX-DLNN (6,1,5,1)	1,402	1,100	1,132	0,613	1,009	0,846
GSTARX-DLNN (6,2,1,1)	1,058	0,927	0,965	0,373	1,107	0,981
GSTARX-DLNN (6,2,2,1)	1,024	0,914	0,962	0,393	1,139	0,876
GSTARX-DLNN (6,2,3,1)	1,177	0,964	1,049	0,520	1,092	0,868
GSTARX-DLNN (6,2,4,1)	1,110	0,929	1,118	0,441	1,188	0,762
GSTARX-DLNN (6,2,5,1)	1,040	0,927	0,964	0,457	1,124	0,905
GSTARX-DLNN (6,3,1,1)	1,094	0,958	0,983	0,543	1,069	0,872
GSTARX-DLNN (6,3,2,1)	1,203	1,087	1,110	0,381	1,045	0,913
GSTARX-DLNN (6,3,3,1)	1,050	0,920	0,978	0,437	1,105	0,899
GSTARX-DLNN (6,3,4,1)	1,041	0,929	0,974	0,404	1,139	0,902
GSTARX-DLNN (6,3,5,1)	1,258	1,131	1,047	0,629	1,079	0,873
GSTARX-DLNN (6,4,1,1)	1,066	0,956	0,980	0,437	1,022	0,993
GSTARX-DLNN (6,4,2,1)*	1,046	0,929	0,980	0,382	1,085	0,836
GSTARX-DLNN (6,4,3,1)	1,037	0,927	1,001	0,470	1,140	0,821
GSTARX-DLNN (6,4,4,1)	1,359	1,050	1,167	0,574	1,038	0,801
GSTARX-DLNN (6,4,5,1)	1,059	0,985	1,263	0,459	1,176	0,686
GSTARX-DLNN (6,5,1,1)	1,228	0,959	1,070	0,529	1,108	0,860
GSTARX-DLNN (6,5,2,1)	1,030	0,922	0,963	0,424	1,129	0,899
GSTARX-DLNN (6,5,3,1)	1,183	0,998	1,135	0,570	1,063	0,812
GSTARX-DLNN (6,5,4,1)	1,052	0,925	0,984	0,345	1,116	0,890
GSTARX-DLNN (6,5,5,1)	1,043	0,917	0,971	0,450	1,133	0,867
GSTARX-DLNN (6,10,1,1)	1,055	0,929	0,976	0,485	1,091	0,822
GSTARX-DLNN (6,10,2,1)	1,053	0,925	0,986	0,436	1,112	0,829
GSTARX-DLNN (6,10,3,1)	1,221	1,091	1,237	0,476	1,047	0,764
GSTARX-DLNN (6,10,4,1)	1,044	0,933	0,988	0,420	1,128	0,850
GSTARX-DLNN (6,10,5,1)	1,162	0,995	1,246	0,549	1,133	0,724
GSTARX-DLNN (6,15,1,1)	1,388	1,044	1,201	0,686	1,068	0,754
GSTARX-DLNN (6,15,2,1)	1,185	1,028	1,078	0,374	1,046	0,963
GSTARX-DLNN (6,15,3,1)	1,050	0,943	0,979	0,444	1,151	0,853
GSTARX-DLNN (6,15,4,1)	1,044	0,936	0,969	0,424	1,100	0,923
GSTARX-DLNN (6,15,5,1)	1,021	0,922	0,962	0,380	1,109	0,888

Ket: *model terbaik

Lampiran 18. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 8 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,116	0,955	1,063	0,842	1,033	0,746
GSTARX-FFNN (6,2,1)	1,125	1,133	1,141	0,803	0,961	0,822
GSTARX-FFNN (6,3,1)	1,044	0,893	1,034	0,851	1,030	0,771
GSTARX-FFNN (6,4,1)	1,310	1,079	1,456	0,824	0,964	0,780
GSTARX-FFNN (6,5,1)	1,168	0,955	1,091	0,762	1,033	0,776
GSTARX-FFNN (6,10,1)*	1,091	0,902	1,073	0,785	1,074	0,698
GSTARX-FFNN (6,15,1)	1,051	1,128	1,175	0,946	0,938	0,714

Lampiran 18. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 8 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,186	0,958	1,094	0,831	1,015	0,858
GSTARX-DLNN (6,1,2,1)	1,346	1,150	1,241	0,885	0,966	0,738
GSTARX-DLNN (6,1,3,1)	1,324	1,058	1,228	0,894	1,002	0,709
GSTARX-DLNN (6,1,4,1)	1,118	0,927	1,065	0,859	1,010	0,770
GSTARX-DLNN (6,1,5,1)	1,141	0,938	1,121	0,813	1,047	0,706
GSTARX-DLNN (6,2,1,1)	1,326	1,192	1,214	0,890	1,001	0,753
GSTARX-DLNN (6,2,2,1)	1,399	1,108	1,288	0,929	0,971	0,774
GSTARX-DLNN (6,2,3,1)	1,095	0,916	1,054	0,825	1,032	0,778
GSTARX-DLNN (6,2,4,1)	1,338	1,052	1,188	0,878	0,985	0,736
GSTARX-DLNN (6,2,5,1)	1,205	0,947	1,240	0,839	1,003	0,674
GSTARX-DLNN (6,3,1,1)	1,363	1,043	1,267	0,889	0,974	0,772
GSTARX-DLNN (6,3,2,1)	1,155	1,090	1,272	0,851	1,037	0,792
GSTARX-DLNN (6,3,3,1)	1,233	0,955	1,076	0,834	0,985	0,779
GSTARX-DLNN (6,3,4,1)	1,085	0,910	1,220	0,859	1,020	0,675
GSTARX-DLNN (6,3,5,1)*	1,178	1,030	1,136	0,804	0,978	0,708
GSTARX-DLNN (6,4,1,1)	1,280	1,003	1,256	0,848	0,974	0,766
GSTARX-DLNN (6,4,2,1)	1,257	0,980	1,382	0,861	0,990	0,669
GSTARX-DLNN (6,4,3,1)	1,116	0,890	1,041	0,819	1,061	0,790
GSTARX-DLNN (6,4,4,1)	1,163	0,989	1,162	0,895	0,983	0,750
GSTARX-DLNN (6,4,5,1)	1,229	1,096	1,427	0,840	0,983	0,794
GSTARX-DLNN (6,5,1,1)	1,278	1,020	1,297	0,855	1,013	0,756
GSTARX-DLNN (6,5,2,1)	1,197	1,229	1,098	0,828	0,960	0,772
GSTARX-DLNN (6,5,3,1)	1,370	1,171	1,292	0,908	0,970	0,682
GSTARX-DLNN (6,5,4,1)	1,124	0,928	1,081	0,782	1,024	0,855
GSTARX-DLNN (6,5,5,1)	1,173	1,066	1,080	0,843	1,010	0,715
GSTARX-DLNN (6,10,1,1)	1,164	0,937	1,176	0,855	1,034	0,679
GSTARX-DLNN (6,10,2,1)	1,153	1,006	1,194	0,853	0,993	0,714
GSTARX-DLNN (6,10,3,1)	1,165	0,970	1,260	0,811	1,032	0,814
GSTARX-DLNN (6,10,4,1)	1,241	1,070	1,448	0,896	1,033	0,770
GSTARX-DLNN (6,10,5,1)	1,216	1,061	1,152	0,856	0,999	0,730
GSTARX-DLNN (6,15,1,1)	1,047	0,905	1,034	0,883	0,987	0,852
GSTARX-DLNN (6,15,2,1)	1,307	1,146	1,211	0,878	1,024	0,662
GSTARX-DLNN (6,15,3,1)	1,129	0,966	1,298	0,829	1,022	0,704
GSTARX-DLNN (6,15,4,1)	1,003	0,921	1,014	0,870	0,983	0,901
GSTARX-DLNN (6,15,5,1)	1,214	0,949	1,070	0,839	1,034	0,766

Ket: *model terbaik

Lampiran 19. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 9 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,124	1,021	1,253	0,967	0,872	1,034
GSTARX-FFNN (6,2,1)	1,164	1,204	1,016	0,972	0,830	1,023
GSTARX-FFNN (6,3,1)*	1,273	1,291	1,146	0,947	0,804	1,070
GSTARX-FFNN (6,4,1)	1,443	1,073	1,393	1,098	0,786	1,036
GSTARX-FFNN (6,5,1)	1,109	0,962	0,962	0,954	0,897	1,133
GSTARX-FFNN (6,10,1)	0,995	1,002	1,095	1,018	0,899	1,043
GSTARX-FFNN (6,15,1)	1,070	1,200	1,107	1,060	0,816	0,999

Lampiran 19. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 9 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,145	1,095	1,010	0,943	0,822	1,014
GSTARX-DLNN (6,1,2,1)	1,307	1,078	1,122	0,902	0,847	1,046
GSTARX-DLNN (6,1,3,1)	1,167	0,990	1,004	0,899	0,916	1,096
GSTARX-DLNN (6,1,4,1)	1,179	0,992	1,083	1,005	0,901	0,987
GSTARX-DLNN (6,1,5,1)	1,166	0,973	1,005	0,922	0,896	1,023
GSTARX-DLNN (6,2,1,1)	1,151	0,997	1,050	0,918	0,901	1,046
GSTARX-DLNN (6,2,2,1)	1,138	1,089	1,002	0,941	0,842	1,041
GSTARX-DLNN (6,2,3,1)	1,117	0,984	0,971	0,930	0,936	1,041
GSTARX-DLNN (6,2,4,1)	1,124	1,034	1,071	0,980	0,849	0,986
GSTARX-DLNN (6,2,5,1)	1,284	1,071	1,262	0,990	0,811	1,043
GSTARX-DLNN (6,3,1,1)	1,224	1,076	1,089	0,905	0,851	1,074
GSTARX-DLNN (6,3,2,1)	1,140	1,025	1,021	0,939	0,939	1,024
GSTARX-DLNN (6,3,3,1)	1,274	1,209	1,216	1,054	0,769	0,998
GSTARX-DLNN (6,3,4,1)	1,357	1,205	1,273	1,067	0,785	1,026
GSTARX-DLNN (6,3,5,1)	1,185	1,061	1,056	0,931	0,817	1,056
GSTARX-DLNN (6,4,1,1)	1,189	1,044	1,023	0,987	0,797	1,008
GSTARX-DLNN (6,4,2,1)	1,142	1,047	1,178	0,954	0,858	1,033
GSTARX-DLNN (6,4,3,1)	1,097	1,238	1,010	0,907	0,797	1,075
GSTARX-DLNN (6,4,4,1)	1,246	1,115	1,046	1,001	0,838	0,994
GSTARX-DLNN (6,4,5,1)	1,170	1,186	1,077	0,944	0,874	1,070
GSTARX-DLNN (6,5,1,1)	1,216	1,057	1,247	0,998	0,798	1,035
GSTARX-DLNN (6,5,2,1)	1,094	1,005	1,022	0,959	0,871	1,069
GSTARX-DLNN (6,5,3,1)	1,149	1,061	1,119	0,943	0,763	0,973
GSTARX-DLNN (6,5,4,1)	1,301	1,232	1,224	1,013	0,798	1,024
GSTARX-DLNN (6,5,5,1)	1,258	1,120	1,298	1,047	0,805	1,017
GSTARX-DLNN (6,10,1,1)	1,181	1,104	1,117	0,968	0,768	1,008
GSTARX-DLNN (6,10,2,1)	1,084	1,027	0,997	0,894	0,816	1,154
GSTARX-DLNN (6,10,3,1)	1,216	1,252	1,071	0,973	0,830	0,980
GSTARX-DLNN (6,10,4,1)*	1,126	0,980	1,007	0,940	0,802	1,035
GSTARX-DLNN (6,10,5,1)	1,090	1,147	1,280	0,956	0,752	1,094
GSTARX-DLNN (6,15,1,1)	1,217	1,148	1,227	1,007	0,813	1,020
GSTARX-DLNN (6,15,2,1)	1,235	1,013	1,325	0,903	0,869	1,052
GSTARX-DLNN (6,15,3,1)	1,334	1,102	1,050	0,995	0,771	0,993
GSTARX-DLNN (6,15,4,1)	1,108	0,976	1,020	0,931	0,876	1,035
GSTARX-DLNN (6,15,5,1)	1,161	0,967	1,049	0,981	0,870	1,013

Ket: *model terbaik

Lampiran 20. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 10 Skenario I

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (6,1,1)	1,519	1,232	1,506	0,689	0,766	1,374
GSTARX-FFNN (6,2,1)	0,993	0,982	0,914	0,746	0,821	1,426
GSTARX-FFNN (6,3,1)	1,013	1,065	0,940	0,784	0,876	1,372
GSTARX-FFNN (6,4,1)	1,006	0,985	0,929	0,758	0,849	1,399
GSTARX-FFNN (6,5,1)	1,024	0,987	0,930	0,777	0,841	1,411
GSTARX-FFNN (6,10,1)	0,995	0,981	0,918	0,715	0,864	1,393
GSTARX-FFNN (6,15,1)*	0,996	0,980	0,917	0,735	0,809	1,413

Lampiran 20. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 10 Skenario I (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (6,1,1,1)	1,124	1,056	1,014	0,739	0,801	1,421
GSTARX-DLNN (6,1,2,1)	1,052	1,050	0,950	0,740	0,806	1,443
GSTARX-DLNN (6,1,3,1)	1,042	1,057	0,964	0,732	0,792	1,404
GSTARX-DLNN (6,1,4,1)	1,094	1,085	0,995	0,701	0,816	1,442
GSTARX-DLNN (6,1,5,1)	1,036	1,000	0,974	0,724	0,834	1,394
GSTARX-DLNN (6,2,1,1)	1,038	1,007	0,946	0,763	0,803	1,405
GSTARX-DLNN (6,2,2,1)	1,365	1,118	1,177	0,752	0,826	1,393
GSTARX-DLNN (6,2,3,1)	1,083	1,028	0,962	0,745	0,806	1,457
GSTARX-DLNN (6,2,4,1)	1,027	0,990	0,953	0,750	0,850	1,372
GSTARX-DLNN (6,2,5,1)	1,235	1,126	1,178	0,739	0,807	1,408
GSTARX-DLNN (6,3,1,1)	1,081	1,056	0,977	0,738	0,790	1,403
GSTARX-DLNN (6,3,2,1)	1,007	0,991	0,927	0,730	0,829	1,431
GSTARX-DLNN (6,3,3,1)	1,018	0,990	0,933	0,727	0,841	1,418
GSTARX-DLNN (6,3,4,1)	1,041	1,033	0,962	0,768	0,818	1,405
GSTARX-DLNN (6,3,5,1)*	0,992	0,979	0,919	0,748	0,850	1,420
GSTARX-DLNN (6,4,1,1)	1,739	1,498	1,552	0,729	0,820	1,360
GSTARX-DLNN (6,4,2,1)	1,047	1,119	0,963	0,738	0,780	1,448
GSTARX-DLNN (6,4,3,1)	1,041	1,030	0,949	0,760	0,831	1,402
GSTARX-DLNN (6,4,4,1)	1,177	1,111	1,066	0,730	0,847	1,421
GSTARX-DLNN (6,4,5,1)	1,803	1,413	1,772	0,730	0,766	1,376
GSTARX-DLNN (6,5,1,1)	1,080	1,057	0,987	0,751	0,826	1,400
GSTARX-DLNN (6,5,2,1)	1,014	1,004	0,931	0,736	0,811	1,441
GSTARX-DLNN (6,5,3,1)	1,429	1,255	1,352	0,721	0,799	1,420
GSTARX-DLNN (6,5,4,1)	1,074	1,018	0,944	0,719	0,822	1,378
GSTARX-DLNN (6,5,5,1)	1,068	1,026	0,986	0,726	0,805	1,428
GSTARX-DLNN (6,10,1,1)	1,024	1,009	0,961	0,737	0,831	1,380
GSTARX-DLNN (6,10,2,1)	1,025	1,032	0,950	0,725	0,819	1,406
GSTARX-DLNN (6,10,3,1)	1,050	1,029	0,957	0,723	0,803	1,373
GSTARX-DLNN (6,10,4,1)	1,009	0,998	0,950	0,746	0,809	1,428
GSTARX-DLNN (6,10,5,1)	1,539	1,445	1,533	0,709	0,934	1,400
GSTARX-DLNN (6,15,1,1)	1,080	1,064	0,981	0,740	0,793	1,438
GSTARX-DLNN (6,15,2,1)	1,124	1,070	0,944	0,796	0,830	1,413
GSTARX-DLNN (6,15,3,1)	1,011	1,017	0,945	0,762	0,833	1,383
GSTARX-DLNN (6,15,4,1)	1,018	1,066	0,952	0,733	0,827	1,418
GSTARX-DLNN (6,15,5,1)	1,021	1,072	0,964	0,770	0,803	1,369

Ket: *model terbaik

Lampiran 21. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 1

System	11:45 Thursday, December 30, 2017 109					The SAS
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
t	1	0.206124	0.004236	48.65	<.0001	
S1	1	21.96929	0.834025	26.34	<.0001	
S2	1	24.84342	0.835863	29.72	<.0001	
S3	1	26.49574	0.837718	31.63	<.0001	
S4	1	24.87698	0.839591	29.63	<.0001	
S5	1	20.67659	0.841480	24.57	<.0001	
S6	1	15.01291	0.853167	17.60	<.0001	
S7	1	11.32409	0.875232	12.94	<.0001	
S8	1	8.250472	0.877534	9.40	<.0001	
S9	1	4.767787	0.888206	5.37	<.0001	
S10	1	9.278803	0.907648	10.22	<.0001	
S11	1	13.16148	0.899901	14.63	<.0001	
S12	1	17.45177	0.872393	20.00	<.0001	
V1t	1	29.31482	1.757256	16.68	<.0001	
V2t	1	41.67778	1.522777	27.37	<.0001	
V3t	1	50.06941	1.518197	32.98	<.0001	
V4t	1	50.74870	1.522359	33.34	<.0001	
V1t1	1	49.97725	1.762206	28.36	<.0001	
V2t1	1	47.20942	1.522644	31.00	<.0001	
V3t1	1	42.38926	1.518190	27.92	<.0001	
V4t1	1	34.36047	1.518151	22.63	<.0001	

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.228633	0.004086	55.96	<.0001
S1	1	25.22742	0.804361	31.36	<.0001
S2	1	28.82786	0.806133	35.76	<.0001
S3	1	29.45359	0.807922	36.46	<.0001
S4	1	28.38610	0.809728	35.06	<.0001
S5	1	24.00628	0.811551	29.58	<.0001
S6	1	19.10364	0.822822	23.22	<.0001
S7	1	14.61578	0.844102	17.32	<.0001
S8	1	11.95442	0.846322	14.13	<.0001
S9	1	8.096704	0.856614	9.45	<.0001
S10	1	13.15659	0.875365	15.03	<.0001
S11	1	15.91187	0.867894	18.33	<.0001
S12	1	21.51075	0.841364	25.57	<.0001
V1t	1	43.69441	1.694755	25.78	<.0001
V2t	1	46.72772	1.468615	31.82	<.0001
V3t	1	56.43885	1.464198	38.55	<.0001
V4t	1	58.89845	1.468212	40.12	<.0001
V1t1	1	59.32575	1.699528	34.91	<.0001
V2t1	1	53.76889	1.468487	36.62	<.0001
V3t1	1	47.18662	1.464191	32.23	<.0001
V4t1	1	36.49262	1.464154	24.92	<.0001

Lampiran 21. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 1
(lanjutan)

Parameter Estimates							
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	
	t	1	0.236044	0.003819	61.81	<.0001	
	S1	1	17.26128	0.751854	22.96	<.0001	
	S2	1	22.06388	0.753511	29.28	<.0001	
	S3	1	23.84203	0.755183	31.57	<.0001	
	S4	1	21.63561	0.756871	28.59	<.0001	
	S5	1	16.20601	0.758575	21.36	<.0001	
	S6	1	10.43909	0.769110	13.57	<.0001	
	S7	1	8.052100	0.789001	10.21	<.0001	
	S8	1	5.026764	0.791076	6.35	<.0001	
	S9	1	3.039848	0.800696	3.80	0.0002	
	S10	1	5.797676	0.818223	7.09	<.0001	
	S11	1	9.493055	0.811239	11.70	<.0001	
	S12	1	12.35705	0.786442	15.71	<.0001	
	V1t	1	35.74027	1.584125	22.56	<.0001	
	V2t	1	38.65331	1.372747	28.16	<.0001	
	V3t	1	49.13809	1.368619	35.90	<.0001	
	V4t	1	51.72540	1.372371	37.69	<.0001	
	V1t1	1	49.23517	1.588587	30.99	<.0001	
	V2t1	1	47.23116	1.372627	34.41	<.0001	
	V3t1	1	44.45612	1.368612	32.48	<.0001	
	V4t1	1	36.92530	1.368577	26.98	<.0001	
Model Parameter Estimates							
Equation	Parameter		Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1		0.14461	0.16326	0.89	0.3770	zresid1(t-1)
	AR1_1_2		0.38909	0.16857	2.31	0.0222	zresid2(t-1)
	AR1_1_3		-0.19547	0.21372	-0.91	0.3617	zresid3(t-1)
	AR2_1_1		0.17277	0.16475	1.05	0.2958	zresid1(t-2)
	AR2_1_2		0.03996	0.17061	0.23	0.8151	zresid2(t-2)
zresid2	AR2_1_3		0.03109	0.21362	0.15	0.8845	zresid3(t-2)
	AR1_2_1		-0.02073	0.15265	-0.14	0.8921	zresid1(t-1)
	AR1_2_2		0.45941	0.15761	2.91	0.0040	zresid2(t-1)
	AR1_2_3		-0.08304	0.19982	-0.42	0.6782	zresid3(t-1)
	AR2_2_1		0.05429	0.15404	0.35	0.7249	zresid1(t-2)
zresid3	AR2_2_2		0.28865	0.15952	1.81	0.0721	zresid2(t-2)
	AR2_2_3		-0.11806	0.19974	-0.59	0.5552	zresid3(t-2)
	AR1_3_1		-0.11708	0.14565	-0.80	0.4226	zresid1(t-1)
	AR1_3_2		0.32236	0.15039	2.14	0.0335	zresid2(t-1)
	AR1_3_3		0.14450	0.19067	0.76	0.4496	zresid3(t-1)
	AR2_3_1		0.01816	0.14698	0.12	0.9018	zresid1(t-2)
	AR2_3_2		0.09949	0.15221	0.65	0.5142	zresid2(t-2)
	AR2_3_3		0.08751	0.19058	0.46	0.6467	zresid3(t-2)

Lampiran 21. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 1
(lanjutan)

2018 28		The SAS System		05:26 Friday, January 4,	
The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi11	1	0.252358	0.080677	3.13	0.0021
w11	1	0.091982	0.099162	0.93	0.3549
lagresi21	1	0.192524	0.081200	2.37	0.0188
w21	1	0.060965	0.099943	0.61	0.5427
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi12	1	0.175344	0.080130	2.19	0.0300
w12	1	0.185685	0.090327	2.06	0.0413
lagresi22	1	0.227786	0.081244	2.80	0.0056
w22	1	0.013206	0.090322	0.15	0.8839
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
lagresi13	1	0.335623	0.085712	3.92	0.0001
w13	1	0.020854	0.091194	0.23	0.8194
lagresi23	1	0.143023	0.085923	1.66	0.0978
w23	1	0.072667	0.091730	0.79	0.4293

Lampiran 22. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 2

2018 152

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.220854	0.004362	50.63	<.0001
S1	1	20.20211	0.858763	23.52	<.0001
S2	1	22.07660	0.860656	25.65	<.0001
S3	1	25.10403	0.862566	29.10	<.0001
S4	1	21.90553	0.864494	25.34	<.0001
S5	1	19.92346	0.866440	22.99	<.0001
S6	1	16.00679	0.878473	18.22	<.0001
S7	1	10.90486	0.901192	12.10	<.0001
S8	1	8.803680	0.903562	9.74	<.0001
S9	1	4.363308	0.914551	4.77	<.0001
S10	1	7.265616	0.934570	7.77	<.0001
S11	1	10.00782	0.926593	10.80	<.0001
S12	1	14.37157	0.898270	16.00	<.0001
V1t	1	32.37106	1.809379	17.89	<.0001
V2t	1	43.98235	1.567944	28.05	<.0001
V3t	1	46.36121	1.563229	29.66	<.0001
V4t	1	52.54736	1.567514	33.52	<.0001
V1t1	1	51.05534	1.814475	28.14	<.0001
V2t1	1	47.57478	1.567807	30.34	<.0001
V3t1	1	38.48398	1.563221	24.62	<.0001
V4t1	1	37.31665	1.563182	23.87	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.241276	0.004123	58.52	<.0001
S1	1	23.17545	0.811663	28.55	<.0001
S2	1	26.63854	0.813451	32.75	<.0001
S3	1	28.01840	0.815257	34.37	<.0001
S4	1	25.92011	0.817079	31.72	<.0001
S5	1	22.54904	0.818918	27.54	<.0001
S6	1	19.85939	0.830292	23.92	<.0001
S7	1	14.38855	0.851765	16.89	<.0001
S8	1	11.83092	0.854005	13.85	<.0001
S9	1	7.604473	0.864391	8.80	<.0001
S10	1	10.23923	0.883312	11.59	<.0001
S11	1	14.20646	0.875773	16.22	<.0001
S12	1	19.10067	0.849002	22.50	<.0001
V1t	1	44.13806	1.710140	25.81	<.0001
V2t	1	50.59014	1.481947	34.14	<.0001
V3t	1	53.80785	1.477491	36.42	<.0001
V4t	1	58.95779	1.481541	39.79	<.0001
V1t1	1	60.44311	1.714956	35.24	<.0001
V2t1	1	56.15464	1.481818	37.90	<.0001
V3t1	1	43.11746	1.477483	29.18	<.0001
V4t1	1	38.46651	1.477446	26.04	<.0001

Lampiran 22. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 2
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.249014	0.003758	66.26	<.0001
S1	1	15.41914	0.739819	20.84	<.0001
S2	1	19.64889	0.741449	26.50	<.0001
S3	1	22.59030	0.743095	30.40	<.0001
S4	1	18.86064	0.744756	25.32	<.0001
S5	1	14.67202	0.746432	19.66	<.0001
S6	1	11.34211	0.756799	14.99	<.0001
S7	1	7.293573	0.776371	9.39	<.0001
S8	1	5.024279	0.778413	6.45	<.0001
S9	1	2.676662	0.787879	3.40	0.0009
S10	1	3.557279	0.805126	4.42	<.0001
S11	1	6.621125	0.798254	8.29	<.0001
S12	1	10.02487	0.773853	12.95	<.0001
V1t	1	37.15094	1.558767	23.83	<.0001
V2t	1	40.52338	1.350773	30.00	<.0001
V3t	1	46.17773	1.346711	34.29	<.0001
V4t	1	54.23864	1.350403	40.16	<.0001
V1t1	1	49.54912	1.563158	31.70	<.0001
V2t1	1	48.15248	1.350655	35.65	<.0001
V3t1	1	40.43745	1.346704	30.03	<.0001
V4t1	1	39.29835	1.346670	29.18	<.0001
The SAS System 19:16 Thursday, January 3,					
2018 196					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.2284343	2.3216075	2.1520927	2.160195	2.0440024
AR 1	2.0204099	2.0402247	1.9705029	2.0340816	2.0122876
AR 2	1.8463035	1.9191219	1.994343	2.051508	2.0187996
AR 3	1.8893347	1.9767067	2.0593353	2.1589221	2.1250034
AR 4	1.9481446	2.0440812	2.1188558	2.2178683	2.2197631
AR 5	2.0224253	2.1015983	2.1712291	2.2285566	2.2490986
AR 6	2.1111494	2.2423711	2.3176154	2.387021	2.4075739
AR 7	2.184695	2.3221906	2.4653366	2.5387429	2.5642646
AR 8	2.2604527	2.4047211	2.5550853	2.7119401	2.7432215
AR 9	2.2591673	2.4107631	2.5689499	2.7341673	2.9068946
AR 10	2.3642805	2.5238217	2.6905065	2.8648258	3.0473162
AR 11	2.4223068	2.5904846	2.7664244	2.9506764	3.1438438
AR 12	2.573638	2.7512279	2.9372744	3.1323964	3.3372744

Lampiran 22. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 2
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.22346	0.16881	1.32	0.1873	zresid1(t-1)
	AR1_1_2	0.06398	0.16585	0.39	0.7002	zresid2(t-1)
	AR1_1_3	-0.00101	0.17143	-0.01	0.9953	zresid3(t-1)
	AR2_1_1	0.79684	0.17036	4.68	0.0001	zresid1(t-2)
	AR2_1_2	-0.24304	0.16561	-1.47	0.1441	zresid2(t-2)
	AR2_1_3	-0.23529	0.16846	-1.40	0.1643	zresid3(t-2)
zresid2	AR1_2_1	0.06377	0.16398	0.39	0.6979	zresid1(t-1)
	AR1_2_2	0.22820	0.16111	1.42	0.1585	zresid2(t-1)
	AR1_2_3	-0.00997	0.16653	-0.06	0.9523	zresid3(t-1)
	AR2_2_1	0.59104	0.16550	3.57	0.0005	zresid1(t-2)
	AR2_2_2	-0.12389	0.16088	-0.77	0.4423	zresid2(t-2)
	AR2_2_3	-0.15268	0.16364	-0.93	0.3521	zresid3(t-2)
zresid3	AR1_3_1	0.12608	0.14435	0.87	0.3836	zresid1(t-1)
	AR1_3_2	0.09406	0.14182	0.66	0.5081	zresid2(t-1)
	AR1_3_3	0.05529	0.14659	0.38	0.7065	zresid3(t-1)
	AR2_3_1	0.49457	0.14568	3.39	0.0009	zresid1(t-2)
	AR2_3_2	-0.23381	0.14162	-1.65	0.1006	zresid2(t-2)
	AR2_3_3	0.06533	0.14405	0.45	0.6508	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 56						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.196331	0.085576	2.29	0.0230
	w11	1	0.108680	0.105944	1.03	0.3064
	lagresi21	1	0.340371	0.086124	3.95	0.0001
	w21	1	0.027541	0.105347	0.26	0.7941
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.222222	0.085425	2.60	0.0101
	w12	1	0.077837	0.098013	0.79	0.4282
	lagresi22	1	0.138612	0.085100	1.63	0.1052
	w22	1	0.228496	0.097475	2.34	0.0202
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.101072	0.082228	1.23	0.2207
	w13	1	0.192213	0.081293	2.36	0.0192
	lagresi23	1	0.275641	0.080946	3.41	0.0008
	w23	1	0.095935	0.081504	1.18	0.2408

Lampiran 23. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 3

2018 298

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.219599	0.004669	47.03	<.0001
S1	1	19.28477	0.919231	20.98	<.0001
S2	1	23.11018	0.921256	25.09	<.0001
S3	1	25.81171	0.923301	27.96	<.0001
S4	1	22.89174	0.925365	24.74	<.0001
S5	1	20.63701	0.927448	22.25	<.0001
S6	1	16.85872	0.940329	17.93	<.0001
S7	1	11.45149	0.964647	11.87	<.0001
S8	1	9.149602	0.967184	9.46	<.0001
S9	1	4.211462	0.978947	4.30	<.0001
S10	1	9.579094	1.000375	9.58	<.0001
S11	1	10.73799	0.991837	10.83	<.0001
S12	1	15.25234	0.961519	15.86	<.0001
V1t	1	33.83716	1.936781	17.47	<.0001
V2t	1	43.48824	1.678347	25.91	<.0001
V3t	1	47.06879	1.673300	28.13	<.0001
V4t	1	50.20592	1.677887	29.92	<.0001
V1t1	1	49.50235	1.942236	25.49	<.0001
V2t1	1	49.04111	1.678200	29.22	<.0001
V3t1	1	38.94946	1.673291	23.28	<.0001
V4t1	1	32.43432	1.673249	19.38	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.239473	0.004294	55.77	<.0001
S1	1	22.63915	0.845346	26.78	<.0001
S2	1	27.10064	0.847209	31.99	<.0001
S3	1	28.72826	0.849089	33.83	<.0001
S4	1	26.52359	0.850987	31.17	<.0001
S5	1	24.03889	0.852903	28.18	<.0001
S6	1	20.70564	0.864748	23.94	<.0001
S7	1	14.23984	0.887112	16.05	<.0001
S8	1	11.79018	0.889445	13.26	<.0001
S9	1	7.554552	0.900262	8.39	<.0001
S10	1	12.23964	0.919969	13.30	<.0001
S11	1	14.02663	0.912117	15.38	<.0001
S12	1	19.29558	0.884235	21.82	<.0001
V1t	1	45.93624	1.781110	25.79	<.0001
V2t	1	50.15038	1.543447	32.49	<.0001
V3t	1	55.55564	1.538806	36.10	<.0001
V4t	1	57.85791	1.543024	37.50	<.0001
V1t1	1	59.77373	1.786126	33.47	<.0001
V2t1	1	56.83477	1.543312	36.83	<.0001
V3t1	1	43.51715	1.538798	28.28	<.0001
V4t1	1	35.78479	1.538759	23.26	<.0001

Lampiran 23. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 3
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.249937	0.003964	63.05	<.0001
S1	1	14.74899	0.780379	18.90	<.0001
S2	1	19.83383	0.782099	25.36	<.0001
S3	1	22.93138	0.783835	29.26	<.0001
S4	1	19.48706	0.785587	24.81	<.0001
S5	1	15.38332	0.787355	19.54	<.0001
S6	1	11.42407	0.798290	14.31	<.0001
S7	1	7.564474	0.818935	9.24	<.0001
S8	1	5.056011	0.821089	6.16	<.0001
S9	1	2.211406	0.831075	2.66	0.0086
S10	1	5.286755	0.849267	6.23	<.0001
S11	1	6.862652	0.842018	8.15	<.0001
S12	1	10.67355	0.816280	13.08	<.0001
V1t	1	38.18246	1.644226	23.22	<.0001
V2t	1	40.58694	1.424829	28.49	<.0001
V3t	1	47.16190	1.420544	33.20	<.0001
V4t	1	51.48539	1.424438	36.14	<.0001
V1t1	1	49.69022	1.648857	30.14	<.0001
V2t1	1	48.95120	1.424705	34.36	<.0001
V3t1	1	41.07689	1.420537	28.92	<.0001
V4t1	1	35.43589	1.420501	24.95	<.0001
The SAS System 19:16 Thursday, January 3, 2018 305					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.7002557	2.6682024	2.4887482	2.4831068	2.5129019
AR 1	2.3874139	2.4904975	2.4987494	2.4971514	2.5102178
AR 2	2.3275435	2.4583807	2.5214635	2.5420694	2.5545123
AR 3	2.3693118	2.4766223	2.55005	2.5976936	2.6049677
AR 4	2.4561072	2.5447698	2.5643484	2.6207235	2.6513126
AR 5	2.5326319	2.5265412	2.5680657	2.6497542	2.7043505
AR 6	2.536495	2.6677167	2.7131125	2.8023713	2.8626768
AR 7	2.5775103	2.7150059	2.858152	2.9522678	3.015049
AR 8	2.6779845	2.8222529	2.9726172	3.129472	3.2000253
AR 9	2.7434263	2.895022	3.0532089	3.2184263	3.3911536
AR 10	2.8821436	3.0416848	3.2083696	3.3826888	3.5651793
AR 11	3.0202591	3.1884369	3.3643768	3.5486288	3.7417961
AR 12	3.0769849	3.2545748	3.4406213	3.6357433	3.8406213

Lampiran 23. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 3
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.15663	0.19377	0.81	0.4200	zresid1(t-1)
	AR1_1_2	0.14282	0.17499	0.82	0.4156	zresid2(t-1)
	AR1_1_3	0.08973	0.18187	0.49	0.6224	zresid3(t-1)
	AR2_1_1	0.33335	0.19630	1.70	0.0913	zresid1(t-2)
	AR2_1_2	-0.00450	0.17576	-0.03	0.9796	zresid2(t-2)
	AR2_1_3	-0.08552	0.18203	-0.47	0.6391	zresid3(t-2)
zresid2	AR1_2_1	0.27191	0.17841	1.52	0.1293	zresid1(t-1)
	AR1_2_2	0.10253	0.16112	0.64	0.5254	zresid2(t-1)
	AR1_2_3	-0.01295	0.16746	-0.08	0.9385	zresid3(t-1)
	AR2_2_1	0.41000	0.18074	2.27	0.0245	zresid1(t-2)
	AR2_2_2	0.04818	0.16183	0.30	0.7663	zresid2(t-2)
	AR2_2_3	-0.34299	0.16760	-2.05	0.0422	zresid3(t-2)
zresid3	AR1_3_1	0.13275	0.16955	0.78	0.4347	zresid1(t-1)
	AR1_3_2	-0.08788	0.15312	-0.57	0.5668	zresid2(t-1)
	AR1_3_3	0.31304	0.15914	1.97	0.0508	zresid3(t-1)
	AR2_3_1	0.20989	0.17176	1.22	0.2234	zresid1(t-2)
	AR2_3_2	0.01426	0.15380	0.09	0.9262	zresid2(t-2)
	AR2_3_3	-0.08445	0.15928	-0.53	0.5967	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 84						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	-0.02202	0.084983	-0.26	0.7959
	w11	1	0.444270	0.108305	4.10	<.0001
	lagresi21	1	0.030590	0.085858	0.36	0.7221
	w21	1	0.266284	0.109119	2.44	0.0157
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.211296	0.080717	2.62	0.0096
	w12	1	0.182685	0.090871	2.01	0.0459
	lagresi22	1	0.198794	0.080481	2.47	0.0145
	w22	1	-0.00859	0.091042	-0.09	0.9250
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.406857	0.078855	5.16	<.0001
	w13	1	-0.02349	0.081847	-0.29	0.7745
	lagresi23	1	0.088557	0.078804	1.12	0.2627
	w23	1	0.085255	0.081569	1.05	0.2974

Lampiran 24. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 4

2018 362

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.190606	0.004111	46.36	<.0001
S1	1	23.04224	0.809373	28.47	<.0001
S2	1	24.90551	0.811157	30.70	<.0001
S3	1	28.33567	0.812957	34.86	<.0001
S4	1	25.69559	0.814774	31.54	<.0001
S5	1	24.33516	0.816608	29.80	<.0001
S6	1	18.16659	0.827950	21.94	<.0001
S7	1	14.61413	0.849362	17.21	<.0001
S8	1	11.51330	0.851596	13.52	<.0001
S9	1	7.658793	0.861952	8.89	<.0001
S10	1	11.81346	0.880820	13.41	<.0001
S11	1	15.63852	0.873302	17.91	<.0001
S12	1	18.75840	0.846608	22.16	<.0001
V1t	1	29.79731	1.705316	17.47	<.0001
V2t	1	42.17633	1.477767	28.54	<.0001
V3t	1	44.64564	1.473323	30.30	<.0001
V4t	1	49.89273	1.477362	33.77	<.0001
V1t1	1	46.01597	1.710119	26.91	<.0001
V2t1	1	46.09790	1.477638	31.20	<.0001
V3t1	1	38.53873	1.473316	26.16	<.0001
V4t1	1	37.27061	1.473278	25.30	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.216249	0.003936	54.95	<.0001
S1	1	26.25705	0.774813	33.89	<.0001
S2	1	29.53394	0.776520	38.03	<.0001
S3	1	31.22796	0.778244	40.13	<.0001
S4	1	30.06638	0.779983	38.55	<.0001
S5	1	27.57571	0.781739	35.27	<.0001
S6	1	22.17703	0.792596	27.98	<.0001
S7	1	17.82353	0.813094	21.92	<.0001
S8	1	13.93026	0.815232	17.09	<.0001
S9	1	10.27678	0.825147	12.45	<.0001
S10	1	14.23001	0.843209	16.88	<.0001
S11	1	18.18929	0.836012	21.76	<.0001
S12	1	22.75919	0.810457	28.08	<.0001
V1t	1	43.42597	1.632499	26.60	<.0001
V2t	1	49.02300	1.414666	34.65	<.0001
V3t	1	53.13245	1.410412	37.67	<.0001
V4t	1	57.47629	1.414278	40.64	<.0001
V1t1	1	57.33854	1.637097	35.02	<.0001
V2t1	1	52.97945	1.414543	37.45	<.0001
V3t1	1	42.13038	1.410405	29.87	<.0001
V4t1	1	37.82174	1.410369	26.82	<.0001

Lampiran 24. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 4
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.221746	0.003674	60.36	<.0001
S1	1	18.20645	0.723216	25.17	<.0001
S2	1	22.52517	0.724809	31.08	<.0001
S3	1	24.75128	0.726418	34.07	<.0001
S4	1	22.43168	0.728042	30.81	<.0001
S5	1	18.99308	0.729681	26.03	<.0001
S6	1	13.65080	0.739815	18.45	<.0001
S7	1	10.66332	0.758948	14.05	<.0001
S8	1	7.325510	0.760944	9.63	<.0001
S9	1	5.512275	0.770198	7.16	<.0001
S10	1	7.894636	0.787057	10.03	<.0001
S11	1	11.44012	0.780339	14.66	<.0001
S12	1	14.02370	0.756486	18.54	<.0001
V1t	1	34.54534	1.523786	22.67	<.0001
V2t	1	40.15788	1.320459	30.41	<.0001
V3t	1	45.63479	1.316488	34.66	<.0001
V4t	1	50.98696	1.320097	38.62	<.0001
V1t1	1	45.41423	1.528077	29.72	<.0001
V2t1	1	46.96999	1.320344	35.57	<.0001
V3t1	1	40.94994	1.316481	31.11	<.0001
V4t1	1	38.60949	1.316448	29.33	<.0001
The SAS System 19:16 Thursday, January 3,					
2018 369					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.7798728	2.837719	2.6308108	2.614167	2.4847069
AR 1	2.4539789	2.4606501	2.3999292	2.4301748	2.3463483
AR 2	2.2837406	2.3667438	2.4163868	2.4580044	2.4166446
AR 3	2.3193302	2.4239263	2.5031828	2.5177307	2.4729065
AR 4	2.276227	2.399242	2.4425558	2.4933392	2.5266511
AR 5	2.3877757	2.4549732	2.5122109	2.540583	2.6509635
AR 6	2.4696061	2.6008278	2.6651957	2.7012291	2.8160852
AR 7	2.5490765	2.686572	2.8297181	2.8732363	2.9960318
AR 8	2.5942458	2.7385142	2.8888785	3.0457333	3.177849
AR 9	2.7032175	2.8548132	3.0130001	3.1782175	3.3509447
AR 10	2.7870433	2.9465845	3.1132693	3.2875885	3.470079
AR 11	2.8400953	3.0082731	3.184213	3.3684649	3.5616323
AR 12	2.9092166	3.0868064	3.2728529	3.4679749	3.6728529

Lampiran 24. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 4
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.18680	0.15539	1.20	0.2310	zresid1(t-1)
	AR1_1_2	-0.07708	0.12741	-0.60	0.5460	zresid2(t-1)
	AR1_1_3	0.14414	0.17684	0.82	0.4162	zresid3(t-1)
	AR2_1_1	0.19657	0.15598	1.26	0.2093	zresid1(t-2)
	AR2_1_2	0.02303	0.12748	0.18	0.8569	zresid2(t-2)
	AR2_1_3	0.21441	0.17800	1.20	0.2300	zresid3(t-2)
zresid2	AR1_2_1	-0.02043	0.15060	-0.14	0.8923	zresid1(t-1)
	AR1_2_2	0.27364	0.12349	2.22	0.0280	zresid2(t-1)
	AR1_2_3	0.03246	0.17139	0.19	0.8500	zresid3(t-1)
	AR2_2_1	0.07081	0.15117	0.47	0.6401	zresid1(t-2)
	AR2_2_2	0.28417	0.12355	2.30	0.0227	zresid2(t-2)
	AR2_2_3	0.00507	0.17251	0.03	0.9766	zresid3(t-2)
zresid3	AR1_3_1	0.12015	0.13907	0.86	0.3888	zresid1(t-1)
	AR1_3_2	-0.08934	0.11403	-0.78	0.4344	zresid2(t-1)
	AR1_3_3	0.22214	0.15826	1.40	0.1622	zresid3(t-1)
	AR2_3_1	0.03235	0.13960	0.23	0.8170	zresid1(t-2)
	AR2_3_2	0.11020	0.11409	0.97	0.3355	zresid2(t-2)
	AR2_3_3	0.24351	0.15930	1.53	0.1282	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 112						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.147711	0.076604	1.93	0.0555
	w11	1	0.111066	0.096049	1.16	0.2491
	lagresi21	1	0.274832	0.076764	3.58	0.0004
	w21	1	0.146068	0.095934	1.52	0.1297
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.388833	0.079603	4.88	<.0001
	w12	1	-0.10236	0.089371	-1.15	0.2537
	lagresi22	1	0.298484	0.079638	3.75	0.0002
	w22	1	0.064892	0.089417	0.73	0.4690
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.157927	0.077815	2.03	0.0439
	w13	1	0.101826	0.083263	1.22	0.2230
	lagresi23	1	0.159816	0.078285	2.04	0.0427
	w23	1	0.215090	0.083491	2.58	0.0108

Lampiran 25. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 5

2018 438

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.219308	0.004202	52.19	<.0001
S1	1	23.38598	0.827224	28.27	<.0001
S2	1	23.77294	0.829047	28.68	<.0001
S3	1	27.36760	0.830887	32.94	<.0001
S4	1	23.18398	0.832745	27.84	<.0001
S5	1	20.53183	0.834619	24.60	<.0001
S6	1	16.38896	0.846210	19.37	<.0001
S7	1	11.96931	0.868095	13.79	<.0001
S8	1	9.271151	0.870378	10.65	<.0001
S9	1	5.072024	0.880963	5.76	<.0001
S10	1	10.27765	0.900247	11.42	<.0001
S11	1	11.91525	0.892563	13.35	<.0001
S12	1	17.08060	0.865280	19.74	<.0001
V1t	1	35.83213	1.742928	20.56	<.0001
V2t	1	41.61165	1.510360	27.55	<.0001
V3t	1	44.20071	1.505818	29.35	<.0001
V4t	1	46.21053	1.509946	30.60	<.0001
V1t1	1	51.87805	1.747837	29.68	<.0001
V2t1	1	47.54742	1.510228	31.48	<.0001
V3t1	1	37.86973	1.505810	25.15	<.0001
V4t1	1	31.57213	1.505772	20.97	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.240307	0.003985	60.30	<.0001
S1	1	25.97825	0.784548	33.11	<.0001
S2	1	27.51698	0.786277	35.00	<.0001
S3	1	29.83583	0.788022	37.86	<.0001
S4	1	27.24097	0.789783	34.49	<.0001
S5	1	23.43071	0.791561	29.60	<.0001
S6	1	20.59438	0.802554	25.66	<.0001
S7	1	14.90579	0.823310	18.10	<.0001
S8	1	12.36048	0.825475	14.97	<.0001
S9	1	7.660595	0.835514	9.17	<.0001
S10	1	12.99281	0.853803	15.22	<.0001
S11	1	15.49163	0.846516	18.30	<.0001
S12	1	21.19775	0.820640	25.83	<.0001
V1t	1	49.14040	1.653010	29.73	<.0001
V2t	1	48.33625	1.432440	33.74	<.0001
V3t	1	51.93545	1.428133	36.37	<.0001
V4t	1	55.24229	1.432048	38.58	<.0001
V1t1	1	61.72223	1.657666	37.23	<.0001
V2t1	1	56.28907	1.432315	39.30	<.0001
V3t1	1	42.82295	1.428125	29.99	<.0001
V4t1	1	33.52311	1.428089	23.47	<.0001

Lampiran 25. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 5
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.249376	0.003471	71.85	<.0001
S1	1	17.89628	0.683318	26.19	<.0001
S2	1	20.60199	0.684824	30.08	<.0001
S3	1	23.93221	0.686344	34.87	<.0001
S4	1	20.32739	0.687878	29.55	<.0001
S5	1	15.47316	0.689426	22.44	<.0001
S6	1	10.99467	0.699001	15.73	<.0001
S7	1	7.450285	0.717079	10.39	<.0001
S8	1	5.446370	0.718965	7.58	<.0001
S9	1	3.227046	0.727708	4.43	<.0001
S10	1	5.420024	0.743638	7.29	<.0001
S11	1	8.101982	0.737291	10.99	<.0001
S12	1	11.67560	0.714753	16.34	<.0001
V1t	1	40.36756	1.439723	28.04	<.0001
V2t	1	38.75450	1.247614	31.06	<.0001
V3t	1	44.44664	1.243862	35.73	<.0001
V4t	1	49.72638	1.247272	39.87	<.0001
V1t1	1	51.25198	1.443778	35.50	<.0001
V2t1	1	48.63911	1.247505	38.99	<.0001
V3t1	1	39.95029	1.243855	32.12	<.0001
V4t1	1	35.37782	1.243824	28.44	<.0001
The SAS System					
2018 445					
19:16 Thursday, January 3,					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.5396115	2.6432615	2.5480994	2.5112417	2.4999371
AR 1	2.3545852	2.3935231	2.4222215	2.4783922	2.5264318
AR 2	2.2818235	2.4063615	2.4901264	2.5649857	2.6126687
AR 3	2.3451119	2.450565	2.5565231	2.6264973	2.6815452
AR 4	2.3915618	2.5071309	2.5911447	2.6811999	2.782792
AR 5	2.4923338	2.5904085	2.6862401	2.7591779	2.8727322
AR 6	2.6046047	2.7358264	2.8384555	2.9132027	3.0343052
AR 7	2.7167162	2.8542118	2.9973579	3.0810686	3.2077679
AR 8	2.8074552	2.9517236	3.1020879	3.2589427	3.3924907
AR 9	2.9010364	3.0526321	3.210819	3.3760364	3.5487636
AR 10	2.9992028	3.158744	3.3254289	3.4997481	3.6822386
AR 11	3.1571234	3.3253012	3.501241	3.685493	3.8786604
AR 12	3.1951152	3.3727051	3.5587516	3.7538735	3.9587516

Lampiran 25. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 5
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.26251	0.14659	1.79	0.0751	zresid1(t-1)
	AR1_1_2	0.12783	0.14229	0.90	0.3702	zresid2(t-1)
	AR1_1_3	-0.04295	0.18543	-0.23	0.8171	zresid3(t-1)
	AR2_1_1	0.32258	0.14802	2.18	0.0307	zresid1(t-2)
	AR2_1_2	-0.01988	0.14275	-0.14	0.8894	zresid2(t-2)
	AR2_1_3	-0.05186	0.18354	-0.28	0.7779	zresid3(t-2)
zresid2	AR1_2_1	0.19122	0.13581	1.41	0.1609	zresid1(t-1)
	AR1_2_2	0.16291	0.13183	1.24	0.2182	zresid2(t-1)
	AR1_2_3	-0.04445	0.17180	-0.26	0.7961	zresid3(t-1)
	AR2_2_1	0.16197	0.13714	1.18	0.2392	zresid1(t-2)
	AR2_2_2	0.15456	0.13226	1.17	0.2442	zresid2(t-2)
	AR2_2_3	0.02146	0.17005	0.13	0.8997	zresid3(t-2)
zresid3	AR1_3_1	0.16301	0.11578	1.41	0.1609	zresid1(t-1)
	AR1_3_2	0.10611	0.11238	0.94	0.3464	zresid2(t-1)
	AR1_3_3	0.03055	0.14646	0.21	0.8350	zresid3(t-1)
	AR2_3_1	0.26484	0.11691	2.27	0.0247	zresid1(t-2)
	AR2_3_2	0.00670	0.11275	0.06	0.9527	zresid2(t-2)
	AR2_3_3	0.01464	0.14496	0.10	0.9197	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 140						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.176390	0.081614	2.16	0.0320
	w11	1	0.200987	0.105268	1.91	0.0579
	lagresi21	1	0.167324	0.082499	2.03	0.0441
	w21	1	0.097513	0.104271	0.94	0.3510
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.143362	0.080784	1.77	0.0777
	w12	1	0.195303	0.094588	2.06	0.0404
	lagresi22	1	0.236766	0.080964	2.92	0.0039
	w22	1	0.104134	0.095464	1.09	0.2769
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.136513	0.080728	1.69	0.0926
	w13	1	0.186250	0.078597	2.37	0.0189
	lagresi23	1	0.073559	0.080101	0.92	0.3597
	w23	1	0.223000	0.079769	2.80	0.0058

Lampiran 26. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 6

2018 502

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.219031	0.004660	47.01	<.0001
S1	1	21.81539	0.917322	23.78	<.0001
S2	1	22.70322	0.919344	24.70	<.0001
S3	1	26.70591	0.921384	28.98	<.0001
S4	1	23.50533	0.923444	25.45	<.0001
S5	1	20.77964	0.925522	22.45	<.0001
S6	1	16.47913	0.938376	17.56	<.0001
S7	1	12.40553	0.962644	12.89	<.0001
S8	1	9.107238	0.965176	9.44	<.0001
S9	1	6.352238	0.976914	6.50	<.0001
S10	1	9.083061	0.998298	9.10	<.0001
S11	1	12.99553	0.989778	13.13	<.0001
S12	1	16.51735	0.959523	17.21	<.0001
V1t	1	33.89582	1.932760	17.54	<.0001
V2t	1	41.03568	1.674862	24.50	<.0001
V3t	1	47.86054	1.669825	28.66	<.0001
V4t	1	52.15391	1.674403	31.15	<.0001
V1t1	1	50.04832	1.938204	25.82	<.0001
V2t1	1	46.29353	1.674716	27.64	<.0001
V3t1	1	39.69710	1.669817	23.77	<.0001
V4t1	1	34.18802	1.669774	20.47	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.243908	0.004300	56.72	<.0001
S1	1	24.50126	0.846520	28.94	<.0001
S2	1	26.26283	0.848386	30.96	<.0001
S3	1	28.89408	0.850269	33.98	<.0001
S4	1	27.76679	0.852169	32.58	<.0001
S5	1	23.49177	0.854087	27.51	<.0001
S6	1	20.29052	0.865949	23.43	<.0001
S7	1	14.01696	0.888345	15.78	<.0001
S8	1	11.90358	0.890681	13.36	<.0001
S9	1	8.134480	0.901513	9.02	<.0001
S10	1	11.96800	0.921246	12.99	<.0001
S11	1	15.66280	0.913383	17.15	<.0001
S12	1	20.32487	0.885464	22.95	<.0001
V1t	1	47.19643	1.783583	26.46	<.0001
V2t	1	46.94101	1.545591	30.37	<.0001
V3t	1	56.01653	1.540943	36.35	<.0001
V4t	1	60.34173	1.545167	39.05	<.0001
V1t1	1	59.30091	1.788607	33.15	<.0001
V2t1	1	54.83964	1.545456	35.48	<.0001
V3t1	1	44.91030	1.540935	29.14	<.0001
V4t1	1	35.77012	1.540896	23.21	<.0001

Lampiran 26. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 6
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.249601	0.004116	60.64	<.0001
S1	1	16.40719	0.810304	20.25	<.0001
S2	1	19.92852	0.812090	24.54	<.0001
S3	1	23.57643	0.813892	28.97	<.0001
S4	1	21.04709	0.815712	25.80	<.0001
S5	1	15.92602	0.817548	19.48	<.0001
S6	1	11.31902	0.828902	13.66	<.0001
S7	1	8.338602	0.850339	9.81	<.0001
S8	1	5.314605	0.852575	6.23	<.0001
S9	1	3.486025	0.862944	4.04	<.0001
S10	1	5.396451	0.881833	6.12	<.0001
S11	1	8.452622	0.874307	9.67	<.0001
S12	1	10.98706	0.847581	12.96	<.0001
V1t	1	39.21503	1.707278	22.97	<.0001
V2t	1	37.75359	1.479467	25.52	<.0001
V3t	1	48.42487	1.475018	32.83	<.0001
V4t	1	52.72676	1.479061	35.65	<.0001
V1t1	1	49.36368	1.712086	28.83	<.0001
V2t1	1	47.41149	1.479338	32.05	<.0001
V3t1	1	41.85233	1.475010	28.37	<.0001
V4t1	1	36.87161	1.474973	25.00	<.0001
The SAS System 19:16 Thursday, January 3, 2018 509					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.4812265	2.6050802	2.4623992	2.3876664	2.3204304
AR 1	2.2051575	2.1606121	2.1378684	2.1519537	2.179948
AR 2	2.0484044	2.0942022	2.1909806	2.2223249	2.2543842
AR 3	2.1030699	2.1180637	2.2032685	2.2793983	2.3608783
AR 4	2.1850641	2.1635079	2.2405996	2.3142447	2.4135185
AR 5	2.2435	2.2591366	2.319931	2.3891308	2.4896768
AR 6	2.2622079	2.3934297	2.4596536	2.528573	2.6305421
AR 7	2.3273426	2.4648382	2.6079842	2.6832889	2.7981394
AR 8	2.4037119	2.5479803	2.6983446	2.8551994	2.9773773
AR 9	2.4754414	2.6270372	2.785224	2.9504414	3.1231687
AR 10	2.5725636	2.7321048	2.8987896	3.0731088	3.2555993
AR 11	2.7128454	2.8810232	3.0569631	3.2412151	3.4343824
AR 12	2.8462152	3.0238051	3.2098516	3.4049735	3.6098516

Lampiran 26. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 6
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.20832	0.17312	1.20	0.2305	zresid1(t-1)
	AR1_1_2	-0.10049	0.15585	-0.64	0.5199	zresid2(t-1)
	AR1_1_3	0.18168	0.19778	0.92	0.3596	zresid3(t-1)
	AR2_1_1	0.17658	0.17406	1.01	0.3118	zresid1(t-2)
	AR2_1_2	-0.02810	0.15453	-0.18	0.8559	zresid2(t-2)
	AR2_1_3	0.32890	0.19732	1.67	0.0974	zresid3(t-2)
zresid2	AR1_2_1	0.11986	0.15450	0.78	0.4389	zresid1(t-1)
	AR1_2_2	0.07403	0.13908	0.53	0.5952	zresid2(t-1)
	AR1_2_3	0.09857	0.17650	0.56	0.5773	zresid3(t-1)
	AR2_2_1	0.23564	0.15534	1.52	0.1311	zresid1(t-2)
	AR2_2_2	0.11275	0.13791	0.82	0.4147	zresid2(t-2)
	AR2_2_3	0.10479	0.17609	0.60	0.5526	zresid3(t-2)
zresid3	AR1_3_1	0.20092	0.15050	1.34	0.1836	zresid1(t-1)
	AR1_3_2	-0.09734	0.13548	-0.72	0.4734	zresid2(t-1)
	AR1_3_3	0.16140	0.17193	0.94	0.3492	zresid3(t-1)
	AR2_3_1	0.16812	0.15131	1.11	0.2681	zresid1(t-2)
	AR2_3_2	0.05907	0.13434	0.44	0.6607	zresid2(t-2)
	AR2_3_3	0.20438	0.17153	1.19	0.2351	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 168						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.113745	0.082891	1.37	0.1718
	w11	1	0.191394	0.103522	1.85	0.0662
	lagresi21	1	0.157264	0.083433	1.88	0.0611
	w21	1	0.306630	0.102701	2.99	0.0032
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.231900	0.080648	2.88	0.0045
	w12	1	0.072502	0.086625	0.84	0.4038
	lagresi22	1	0.221939	0.080004	2.77	0.0061
	w22	1	0.235399	0.087502	2.69	0.0078
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.101835	0.081403	1.25	0.2126
	w13	1	0.179290	0.085695	2.09	0.0379
	lagresi23	1	0.107230	0.081404	1.32	0.1895
	w23	1	0.313134	0.085117	3.68	0.0003

Lampiran 27. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 7

2018 574

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.204163	0.004515	45.22	<.0001
S1	1	22.42790	0.888808	25.23	<.0001
S2	1	24.11364	0.890767	27.07	<.0001
S3	1	28.00905	0.892744	31.37	<.0001
S4	1	24.12901	0.894739	26.97	<.0001
S5	1	23.15651	0.896753	25.82	<.0001
S6	1	17.71692	0.909207	19.49	<.0001
S7	1	15.73677	0.932721	16.87	<.0001
S8	1	11.48230	0.935174	12.28	<.0001
S9	1	7.534846	0.946547	7.96	<.0001
S10	1	12.62655	0.967267	13.05	<.0001
S11	1	13.82116	0.959011	14.41	<.0001
S12	1	17.75391	0.929697	19.10	<.0001
V1t	1	33.50079	1.872682	17.89	<.0001
V2t	1	43.73365	1.622800	26.95	<.0001
V3t	1	46.46608	1.617920	28.72	<.0001
V4t	1	47.86363	1.622355	29.50	<.0001
V1t1	1	50.85205	1.877956	27.08	<.0001
V2t1	1	45.46634	1.622659	28.02	<.0001
V3t1	1	37.86257	1.617912	23.40	<.0001
V4t1	1	33.91743	1.617871	20.96	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.227580	0.004301	52.92	<.0001
S1	1	25.14845	0.846683	29.70	<.0001
S2	1	27.51053	0.848549	32.42	<.0001
S3	1	30.84472	0.850432	36.27	<.0001
S4	1	28.36260	0.852333	33.28	<.0001
S5	1	25.72856	0.854252	30.12	<.0001
S6	1	21.33519	0.866116	24.63	<.0001
S7	1	18.12517	0.888515	20.40	<.0001
S8	1	14.43326	0.890852	16.20	<.0001
S9	1	9.942290	0.901686	11.03	<.0001
S10	1	14.99647	0.921423	16.28	<.0001
S11	1	16.25763	0.913559	17.80	<.0001
S12	1	21.68216	0.885634	24.48	<.0001
V1t	1	45.97253	1.783926	25.77	<.0001
V2t	1	50.15937	1.545888	32.45	<.0001
V3t	1	53.60662	1.541239	34.78	<.0001
V4t	1	56.71256	1.545464	36.70	<.0001
V1t1	1	60.38907	1.788951	33.76	<.0001
V2t1	1	53.99945	1.545753	34.93	<.0001
V3t1	1	42.99336	1.541231	27.90	<.0001
V4t1	1	36.11498	1.541192	23.43	<.0001

Lampiran 27. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 7
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.235193	0.003942	59.67	<.0001
S1	1	17.48085	0.776005	22.53	<.0001
S2	1	21.05167	0.777715	27.07	<.0001
S3	1	24.99054	0.779441	32.06	<.0001
S4	1	21.66958	0.781183	27.74	<.0001
S5	1	17.97975	0.782941	22.96	<.0001
S6	1	12.89116	0.793815	16.24	<.0001
S7	1	10.89880	0.814345	13.38	<.0001
S8	1	7.332970	0.816486	8.98	<.0001
S9	1	5.221982	0.826416	6.32	<.0001
S10	1	8.127404	0.844506	9.62	<.0001
S11	1	9.719625	0.837298	11.61	<.0001
S12	1	12.98045	0.811704	15.99	<.0001
V1t	1	38.04140	1.635010	23.27	<.0001
V2t	1	40.36528	1.416842	28.49	<.0001
V3t	1	45.95860	1.412581	32.54	<.0001
V4t	1	51.18367	1.416454	36.14	<.0001
V1t1	1	50.44741	1.639615	30.77	<.0001
V2t1	1	46.51370	1.416718	32.83	<.0001
V3t1	1	39.56184	1.412574	28.01	<.0001
V4t1	1	37.15153	1.412538	26.30	<.0001
The SAS System					
19:16 Thursday, January 3,					
2018 581					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.4091634	2.4341429	2.28777	2.2785754	2.2800582
AR 1	2.2147062	2.3376912	2.2870802	2.2728927	2.2781944
AR 2	2.202221	2.2997945	2.3343832	2.3453538	2.3151421
AR 3	2.1735187	2.2930072	2.3554529	2.4258177	2.3617139
AR 4	2.2178581	2.2928623	2.3552779	2.4188338	2.4206219
AR 5	2.2696977	2.3429477	2.3696974	2.4227199	2.4953861
AR 6	2.3467037	2.4779254	2.5112423	2.5732198	2.6508792
AR 7	2.3829653	2.5204609	2.663607	2.7319845	2.8146905
AR 8	2.4610297	2.6052982	2.7556624	2.9125172	3.0029893
AR 9	2.5436345	2.6952302	2.8534171	3.0186345	3.1913617
AR 10	2.6817796	2.8413208	3.0080056	3.1823249	3.3648153
AR 11	2.7991641	2.9673419	3.1432818	3.3275338	3.5207011
AR 12	2.916552	3.0941419	3.2801884	3.4753103	3.6801884

Lampiran 27. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 7
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.41281	0.16674	2.48	0.0143	zresid1(t-1)
	AR1_1_2	0.07765	0.17704	0.44	0.6615	zresid2(t-1)
	AR1_1_3	-0.14588	0.19631	-0.74	0.4584	zresid3(t-1)
	AR2_1_1	0.24832	0.16959	1.46	0.1449	zresid1(t-2)
	AR2_1_2	0.43812	0.17630	2.49	0.0139	zresid2(t-2)
	AR2_1_3	-0.56893	0.19659	-2.89	0.0043	zresid3(t-2)
zresid2	AR1_2_1	0.32306	0.15825	2.04	0.0427	zresid1(t-1)
	AR1_2_2	0.12254	0.16803	0.73	0.4668	zresid2(t-1)
	AR1_2_3	-0.10441	0.18631	-0.56	0.5759	zresid3(t-1)
	AR2_2_1	0.23047	0.16095	1.43	0.1540	zresid1(t-2)
	AR2_2_2	0.43245	0.16732	2.58	0.0106	zresid2(t-2)
	AR2_2_3	-0.53796	0.18657	-2.88	0.0044	zresid3(t-2)
zresid3	AR1_3_1	0.19484	0.14724	1.32	0.1875	zresid1(t-1)
	AR1_3_2	0.09116	0.15634	0.58	0.5606	zresid2(t-1)
	AR1_3_3	0.01667	0.17335	0.10	0.9235	zresid3(t-1)
	AR2_3_1	0.26442	0.14975	1.77	0.0792	zresid1(t-2)
	AR2_3_2	0.32778	0.15568	2.11	0.0367	zresid2(t-2)
	AR2_3_3	-0.45529	0.17360	-2.62	0.0095	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 196						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.266881	0.090015	2.96	0.0035
	w11	1	0.128316	0.108908	1.18	0.2403
	lagresi21	1	0.038083	0.091161	0.42	0.6766
	w21	1	0.130888	0.108477	1.21	0.2292
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.103080	0.089135	1.16	0.2491
	w12	1	0.291302	0.100340	2.90	0.0042
	lagresi22	1	0.139498	0.088915	1.57	0.1185
	w22	1	0.031908	0.100759	0.32	0.7519
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.201608	0.087916	2.29	0.0230
	w13	1	0.142923	0.090046	1.59	0.1143
	lagresi23	1	0.022655	0.088123	0.26	0.7974
	w23	1	0.154381	0.091064	1.70	0.0918

Lampiran 28. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 8

2018 638

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.198644	0.004064	48.87	<.0001
S1	1	21.92773	0.800169	27.40	<.0001
S2	1	25.16728	0.801932	31.38	<.0001
S3	1	28.51045	0.803712	35.47	<.0001
S4	1	25.14699	0.805509	31.22	<.0001
S5	1	22.35059	0.807322	27.68	<.0001
S6	1	16.83015	0.818534	20.56	<.0001
S7	1	11.69502	0.839703	13.93	<.0001
S8	1	10.46887	0.841911	12.43	<.0001
S9	1	6.288367	0.852150	7.38	<.0001
S10	1	9.967245	0.870803	11.45	<.0001
S11	1	12.93397	0.863371	14.98	<.0001
S12	1	17.67850	0.836980	21.12	<.0001
V1t	1	32.78831	1.685923	19.45	<.0001
V2t	1	41.09355	1.460961	28.13	<.0001
V3t	1	47.69769	1.456568	32.75	<.0001
V4t	1	47.46199	1.460561	32.50	<.0001
V1t1	1	47.54680	1.690671	28.12	<.0001
V2t1	1	45.92105	1.460834	31.43	<.0001
V3t1	1	39.35264	1.456560	27.02	<.0001
V4t1	1	35.18701	1.456524	24.16	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.221263	0.003893	56.84	<.0001
S1	1	24.88940	0.766343	32.48	<.0001
S2	1	29.16657	0.768032	37.98	<.0001
S3	1	31.20453	0.769737	40.54	<.0001
S4	1	29.36626	0.771457	38.07	<.0001
S5	1	25.65170	0.773194	33.18	<.0001
S6	1	20.09900	0.783932	25.64	<.0001
S7	1	15.19089	0.804206	18.89	<.0001
S8	1	12.59640	0.806321	15.62	<.0001
S9	1	8.762276	0.816127	10.74	<.0001
S10	1	12.54791	0.833992	15.05	<.0001
S11	1	15.51028	0.826873	18.76	<.0001
S12	1	21.50209	0.801598	26.82	<.0001
V1t	1	46.24330	1.614653	28.64	<.0001
V2t	1	48.25117	1.399202	34.48	<.0001
V3t	1	55.30454	1.394994	39.64	<.0001
V4t	1	55.15147	1.398818	39.43	<.0001
V1t1	1	58.22114	1.619201	35.96	<.0001
V2t1	1	54.32305	1.399080	38.83	<.0001
V3t1	1	44.27663	1.394987	31.74	<.0001
V4t1	1	37.23099	1.394952	26.69	<.0001

Lampiran 28. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 8
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.234020	0.003595	65.10	<.0001
S1	1	16.75280	0.707710	23.67	<.0001
S2	1	21.72717	0.709270	30.63	<.0001
S3	1	25.19919	0.710844	35.45	<.0001
S4	1	21.80745	0.712433	30.61	<.0001
S5	1	17.46778	0.714036	24.46	<.0001
S6	1	11.34275	0.723953	15.67	<.0001
S7	1	7.645159	0.742676	10.29	<.0001
S8	1	5.869141	0.744629	7.88	<.0001
S9	1	3.540373	0.753685	4.70	<.0001
S10	1	5.264405	0.770183	6.84	<.0001
S11	1	8.588169	0.763609	11.25	<.0001
S12	1	12.90775	0.740267	17.44	<.0001
V1t	1	37.95330	1.491116	25.45	<.0001
V2t	1	38.42431	1.292149	29.74	<.0001
V3t	1	46.77624	1.288263	36.31	<.0001
V4t	1	51.31181	1.291794	39.72	<.0001
V1t1	1	47.28803	1.495316	31.62	<.0001
V2t1	1	46.91454	1.292036	36.31	<.0001
V3t1	1	41.26462	1.288256	32.03	<.0001
V4t1	1	39.29709	1.288224	30.50	<.0001
The SAS System 19:16 Thursday, January 3,					
2018 645					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.6006408	2.5834614	2.3680123	2.3694682	2.3181426
AR 1	2.2466268	2.318582	2.3026951	2.3068738	2.3283343
AR 2	2.1123314	2.2433525	2.3146342	2.3695266	2.4129183
AR 3	2.1970821	2.2875262	2.3972198	2.4099416	2.4826451
AR 4	2.2581731	2.3304661	2.4162599	2.4823128	2.5762571
AR 5	2.3397839	2.4031047	2.4704496	2.5785958	2.6537855
AR 6	2.3902916	2.5215134	2.5936441	2.7034267	2.7856392
AR 7	2.4684604	2.6059559	2.749102	2.8685366	2.959416
AR 8	2.5103939	2.6546623	2.8050266	2.9618814	3.0655013
AR 9	2.6178853	2.769481	2.9276679	3.0928853	3.2656126
AR 10	2.7361627	2.8957039	3.0623887	3.236708	3.4191984
AR 11	2.8528366	3.0210144	3.1969542	3.3812062	3.5743736
AR 12	2.8711082	3.048698	3.2347445	3.4298665	3.6347445

Lampiran 28. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 8
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.25257	0.14255	1.77	0.0782	zresid1(t-1)
	AR1_1_2	0.11713	0.15603	0.75	0.4539	zresid2(t-1)
	AR1_1_3	-0.12286	0.15727	-0.78	0.4358	zresid3(t-1)
	AR2_1_1	0.39014	0.13705	2.85	0.0050	zresid1(t-2)
	AR2_1_2	0.09879	0.15499	0.64	0.5247	zresid2(t-2)
	AR2_1_3	-0.17964	0.16102	-1.12	0.2661	zresid3(t-2)
zresid2	AR1_2_1	0.15426	0.12961	1.19	0.2356	zresid1(t-1)
	AR1_2_2	0.15879	0.14186	1.12	0.2646	zresid2(t-1)
	AR1_2_3	0.02682	0.14299	0.19	0.8514	zresid3(t-1)
	AR2_2_1	0.11286	0.12461	0.91	0.3663	zresid1(t-2)
	AR2_2_2	0.16144	0.14092	1.15	0.2535	zresid2(t-2)
	AR2_2_3	0.09988	0.14640	0.68	0.4960	zresid3(t-2)
zresid3	AR1_3_1	0.06278	0.12283	0.51	0.6099	zresid1(t-1)
	AR1_3_2	0.00585	0.13444	0.04	0.9654	zresid2(t-1)
	AR1_3_3	0.29601	0.13551	2.18	0.0303	zresid3(t-1)
	AR2_3_1	0.21431	0.11809	1.81	0.0713	zresid1(t-2)
	AR2_3_2	-0.03272	0.13355	-0.24	0.8068	zresid2(t-2)
	AR2_3_3	0.08162	0.13874	0.59	0.5571	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 224						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.250022	0.080235	3.12	0.0021
	w11	1	0.011822	0.103055	0.11	0.9088
	lagresi21	1	0.343419	0.079113	4.34	<.0001
	w21	1	-0.01728	0.100820	-0.17	0.8641
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.107490	0.079215	1.36	0.1766
	w12	1	0.244199	0.089746	2.72	0.0072
	lagresi22	1	0.152689	0.078936	1.93	0.0547
	w22	1	0.219307	0.090529	2.42	0.0164
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.382324	0.081537	4.69	<.0001
	w13	1	-0.00510	0.083250	-0.06	0.9513
	lagresi23	1	0.111745	0.081419	1.37	0.1717
	w23	1	0.152340	0.083973	1.81	0.0714

Lampiran 29. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 9

2018 702

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.210316	0.004438	47.39	<.0001
S1	1	22.86232	0.873699	26.17	<.0001
S2	1	23.20132	0.875624	26.50	<.0001
S3	1	26.95659	0.877568	30.72	<.0001
S4	1	22.88587	0.879529	26.02	<.0001
S5	1	21.26941	0.881509	24.13	<.0001
S6	1	16.48954	0.893752	18.45	<.0001
S7	1	11.20805	0.916866	12.22	<.0001
S8	1	9.695907	0.919277	10.55	<.0001
S9	1	4.452939	0.930457	4.79	<.0001
S10	1	9.975765	0.950824	10.49	<.0001
S11	1	13.33188	0.942709	14.14	<.0001
S12	1	18.32034	0.913892	20.05	<.0001
V1t	1	33.35056	1.840848	18.12	<.0001
V2t	1	42.05237	1.595214	26.36	<.0001
V3t	1	45.91467	1.590417	28.87	<.0001
V4t	1	49.31170	1.594777	30.92	<.0001
V1t1	1	50.12412	1.846032	27.15	<.0001
V2t1	1	47.97914	1.595075	30.08	<.0001
V3t1	1	37.80225	1.590409	23.77	<.0001
V4t1	1	35.23269	1.590368	22.15	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.225569	0.004289	52.60	<.0001
S1	1	25.92032	0.844275	30.70	<.0001
S2	1	27.84209	0.846135	32.91	<.0001
S3	1	30.18422	0.848014	35.59	<.0001
S4	1	27.53090	0.849909	32.39	<.0001
S5	1	25.17219	0.851822	29.55	<.0001
S6	1	20.98881	0.863652	24.30	<.0001
S7	1	15.22938	0.885988	17.19	<.0001
S8	1	12.84682	0.888318	14.46	<.0001
S9	1	8.031409	0.899121	8.93	<.0001
S10	1	12.83603	0.918803	13.97	<.0001
S11	1	16.59362	0.910961	18.22	<.0001
S12	1	21.51654	0.883115	24.36	<.0001
V1t	1	46.35248	1.778853	26.06	<.0001
V2t	1	48.80017	1.541491	31.66	<.0001
V3t	1	55.22459	1.536856	35.93	<.0001
V4t	1	57.85245	1.541069	37.54	<.0001
V1t1	1	60.45532	1.783863	33.89	<.0001
V2t1	1	55.71067	1.541357	36.14	<.0001
V3t1	1	42.69666	1.536848	27.78	<.0001
V4t1	1	36.58167	1.536809	23.80	<.0001

Lampiran 29. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 9
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.238636	0.003969	60.12	<.0001
S1	1	17.57696	0.781420	22.49	<.0001
S2	1	20.57986	0.783142	26.28	<.0001
S3	1	23.72306	0.784880	30.23	<.0001
S4	1	19.88784	0.786635	25.28	<.0001
S5	1	16.06553	0.788405	20.38	<.0001
S6	1	10.85891	0.799355	13.58	<.0001
S7	1	7.740341	0.820028	9.44	<.0001
S8	1	5.337386	0.822184	6.49	<.0001
S9	1	2.173218	0.832183	2.61	0.0099
S10	1	5.706222	0.850399	6.71	<.0001
S11	1	9.111500	0.843141	10.81	<.0001
S12	1	13.00589	0.817368	15.91	<.0001
V1t	1	38.81014	1.646419	23.57	<.0001
V2t	1	40.31048	1.426729	28.25	<.0001
V3t	1	47.14589	1.422439	33.14	<.0001
V4t	1	52.02281	1.426338	36.47	<.0001
V1t1	1	49.49621	1.651057	29.98	<.0001
V2t1	1	48.99501	1.426605	34.34	<.0001
V3t1	1	39.62585	1.422431	27.86	<.0001
V4t1	1	38.41710	1.422396	27.01	<.0001
The SAS System 19:16 Thursday, January 3, 2018 709					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.2767306	2.2851037	2.2176637	2.2117166	2.2321732
AR 1	2.0314267	2.1416426	2.1534906	2.2230834	2.2305379
AR 2	2.0119563	2.1530618	2.2470239	2.3256155	2.335568
AR 3	2.1158447	2.2334807	2.3152775	2.3910176	2.4120918
AR 4	2.1671014	2.275433	2.35502	2.3890794	2.4606725
AR 5	2.1672314	2.2389257	2.3407575	2.4487192	2.5461129
AR 6	2.239956	2.3711778	2.4802889	2.5944122	2.6960832
AR 7	2.3324723	2.4699679	2.6131139	2.7314641	2.841481
AR 8	2.4606906	2.604959	2.7553232	2.912178	3.0313153
AR 9	2.5524183	2.704014	2.8622009	3.0274183	3.2001455
AR 10	2.6428302	2.8023714	2.9690562	3.1433754	3.3258659
AR 11	2.7235247	2.8917024	3.0676423	3.2518943	3.4450617
AR 12	2.7813596	2.9589495	3.144996	3.3401179	3.544996

Lampiran 29. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 9
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	-0.05329	0.17475	-0.30	0.7608	zresid1(t-1)
	AR1_1_2	0.18534	0.18135	1.02	0.3082	zresid2(t-1)
	AR1_1_3	0.24394	0.19898	1.23	0.2219	zresid3(t-1)
	AR2_1_1	0.20464	0.17789	1.15	0.2516	zresid1(t-2)
	AR2_1_2	-0.25847	0.17853	-1.45	0.1495	zresid2(t-2)
	AR2_1_3	0.34626	0.20042	1.73	0.0858	zresid3(t-2)
zresid2	AR1_2_1	-0.34880	0.16939	-2.06	0.0410	zresid1(t-1)
	AR1_2_2	0.34150	0.17579	1.94	0.0537	zresid2(t-1)
	AR1_2_3	0.39580	0.19287	2.05	0.0417	zresid3(t-1)
	AR2_2_1	0.21049	0.17244	1.22	0.2239	zresid1(t-2)
	AR2_2_2	-0.24540	0.17305	-1.42	0.1580	zresid2(t-2)
	AR2_2_3	0.27129	0.19427	1.40	0.1644	zresid3(t-2)
zresid3	AR1_3_1	-0.12992	0.15631	-0.83	0.4070	zresid1(t-1)
	AR1_3_2	0.15432	0.16221	0.95	0.3428	zresid2(t-1)
	AR1_3_3	0.33363	0.17798	1.87	0.0626	zresid3(t-1)
	AR2_3_1	0.20656	0.15912	1.30	0.1960	zresid1(t-2)
	AR2_3_2	-0.27449	0.15969	-1.72	0.0874	zresid2(t-2)
	AR2_3_3	0.31108	0.17927	1.74	0.0845	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 308						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.240982	0.087518	2.75	0.0065
	w11	1	0.109167	0.104544	1.04	0.2978
	lagresi21	1	0.048101	0.087858	0.55	0.5847
	w21	1	0.232547	0.106240	2.19	0.0299
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.275196	0.089065	3.09	0.0023
	w12	1	0.071395	0.101258	0.71	0.4817
	lagresi22	1	0.081027	0.089119	0.91	0.3645
	w22	1	0.146482	0.100614	1.46	0.1472
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.110785	0.086552	1.28	0.2023
	w13	1	0.219747	0.088857	2.47	0.0144
	lagresi23	1	0.125318	0.086935	1.44	0.1512
	w23	1	0.111082	0.088218	1.26	0.2097

Lampiran 30. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 10

2018 766

The SAS System

19:16 Thursday, January 3,

The SYSLIN Procedure

Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.213876	0.004414	48.45	<.0001
S1	1	21.45551	0.869040	24.69	<.0001
S2	1	23.61286	0.870955	27.11	<.0001
S3	1	26.58743	0.872888	30.46	<.0001
S4	1	24.62626	0.874840	28.15	<.0001
S5	1	20.66281	0.876809	23.57	<.0001
S6	1	16.89371	0.888986	19.00	<.0001
S7	1	11.51268	0.911977	12.62	<.0001
S8	1	10.19424	0.914375	11.15	<.0001
S9	1	4.501230	0.925495	4.86	<.0001
S10	1	9.706554	0.945754	10.26	<.0001
S11	1	11.77259	0.937682	12.55	<.0001
S12	1	16.85386	0.909019	18.54	<.0001
V1t	1	33.43764	1.831032	18.26	<.0001
V2t	1	43.52930	1.586708	27.43	<.0001
V3t	1	47.45288	1.581936	30.00	<.0001
V4t	1	49.88800	1.586273	31.45	<.0001
V1t1	1	50.44989	1.836189	27.48	<.0001
V2t1	1	44.20822	1.586569	27.86	<.0001
V3t1	1	37.93896	1.581928	23.98	<.0001
V4t1	1	33.73603	1.581888	21.33	<.0001

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.239629	0.004217	56.82	<.0001
S1	1	24.30626	0.830211	29.28	<.0001
S2	1	27.33622	0.832040	32.85	<.0001
S3	1	28.93413	0.833887	34.70	<.0001
S4	1	27.78811	0.835751	33.25	<.0001
S5	1	22.92937	0.837632	27.37	<.0001
S6	1	20.41307	0.849265	24.04	<.0001
S7	1	13.90342	0.871229	15.96	<.0001
S8	1	12.30917	0.873520	14.09	<.0001
S9	1	7.330884	0.884144	8.29	<.0001
S10	1	12.40249	0.903497	13.73	<.0001
S11	1	14.92830	0.895786	16.67	<.0001
S12	1	20.44834	0.868404	23.55	<.0001
V1t	1	45.98781	1.749220	26.29	<.0001
V2t	1	49.85515	1.515812	32.89	<.0001
V3t	1	55.94023	1.511254	37.02	<.0001
V4t	1	57.87149	1.515397	38.19	<.0001
V1t1	1	60.79867	1.754147	34.66	<.0001
V2t1	1	51.81191	1.515680	34.18	<.0001
V3t1	1	42.03776	1.511246	27.82	<.0001
V4t1	1	35.62080	1.511208	23.57	<.0001

Lampiran 30. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 10
(lanjutan)

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
t	1	0.246076	0.003952	62.27	<.0001
S1	1	16.42565	0.777924	21.11	<.0001
S2	1	20.58380	0.779638	26.40	<.0001
S3	1	23.61792	0.781369	30.23	<.0001
S4	1	21.13463	0.783115	26.99	<.0001
S5	1	15.67927	0.784878	19.98	<.0001
S6	1	11.56363	0.795778	14.53	<.0001
S7	1	7.600795	0.816359	9.31	<.0001
S8	1	5.879311	0.818506	7.18	<.0001
S9	1	2.613038	0.828460	3.15	0.0019
S10	1	5.147758	0.846595	6.08	<.0001
S11	1	7.763932	0.839369	9.25	<.0001
S12	1	11.73438	0.813711	14.42	<.0001
V1t	1	37.65800	1.639053	22.98	<.0001
V2t	1	40.52457	1.420346	28.53	<.0001
V3t	1	47.71346	1.416075	33.69	<.0001
V4t	1	51.88912	1.419957	36.54	<.0001
V1t1	1	49.75972	1.643670	30.27	<.0001
V2t1	1	45.65964	1.420222	32.15	<.0001
V3t1	1	39.50780	1.416068	27.90	<.0001
V4t1	1	36.53717	1.416032	25.80	<.0001
The SAS System 19:16 Thursday, January 3,					
2018 773					
The VARMAX Procedure					
Minimum Information Criterion					
Lag	MA 0	MA 1	MA 2	MA 3	MA 4
AR 0	2.8776049	2.8410876	2.519237	2.4358213	2.3033428
AR 1	2.3237678	2.3737132	2.2911208	2.3541846	2.3377161
AR 2	2.1709954	2.2563221	2.3365281	2.389634	2.3984861
AR 3	2.1834882	2.3025375	2.4014995	2.4539161	2.4680781
AR 4	2.25204	2.3588425	2.4125129	2.4695948	2.533993
AR 5	2.3434155	2.3738803	2.4647187	2.5492809	2.6348649
AR 6	2.3901197	2.5213414	2.6190193	2.7084976	2.8030012
AR 7	2.5002269	2.6377225	2.7808686	2.8764019	2.979117
AR 8	2.5620828	2.7063512	2.8567155	3.0135703	3.1231536
AR 9	2.6556309	2.8072266	2.9654135	3.1306309	3.3033582
AR 10	2.7460394	2.9055805	3.0722654	3.2465846	3.4290751
AR 11	2.845756	3.0139338	3.1898736	3.3741256	3.567293
AR 12	2.8241343	3.0017242	3.1877707	3.3828926	3.5877707

Lampiran 30. Output SAS Pemodelan VARX dan GSTARX Skenario II Data Simulasi 10
(lanjutan)

Model Parameter Estimates						
Equation	Parameter	Estimate	Standard Error	t Value	Pr > t	Variable
zresid1	AR1_1_1	0.34927	0.15319	2.28	0.0238	zresid1(t-1)
	AR1_1_2	0.06110	0.14162	0.43	0.6667	zresid2(t-1)
	AR1_1_3	0.01283	0.16861	0.08	0.9395	zresid3(t-1)
	AR2_1_1	0.29112	0.15171	1.92	0.0566	zresid1(t-2)
	AR2_1_2	0.13638	0.14279	0.96	0.3409	zresid2(t-2)
	AR2_1_3	-0.15538	0.16911	-0.92	0.3595	zresid3(t-2)
zresid2	AR1_2_1	0.17266	0.14477	1.19	0.2346	zresid1(t-1)
	AR1_2_2	0.22798	0.13384	1.70	0.0903	zresid2(t-1)
	AR1_2_3	-0.03099	0.15935	-0.19	0.8460	zresid3(t-1)
	AR2_2_1	-0.01125	0.14337	-0.08	0.9375	zresid1(t-2)
	AR2_2_2	0.30819	0.13495	2.28	0.0236	zresid2(t-2)
	AR2_2_3	0.06188	0.15982	0.39	0.6991	zresid3(t-2)
zresid3	AR1_3_1	0.10387	0.13617	0.76	0.4467	zresid1(t-1)
	AR1_3_2	-0.05682	0.12590	-0.45	0.6523	zresid2(t-1)
	AR1_3_3	0.31327	0.14988	2.09	0.0381	zresid3(t-1)
	AR2_3_1	0.11183	0.13486	0.83	0.4081	zresid1(t-2)
	AR2_3_2	0.07724	0.12693	0.61	0.5436	zresid2(t-2)
	AR2_3_3	0.15459	0.15033	1.03	0.3052	zresid3(t-2)
The SAS System 05:26 Friday, January 4,						
2018 280						
The SYSLIN Procedure						
Seemingly Unrelated Regression Estimation						
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi11	1	0.253198	0.080747	3.14	0.0020
	w11	1	0.182858	0.098258	1.86	0.0644
	lagresi21	1	0.266591	0.080609	3.31	0.0011
	w21	1	0.016759	0.097572	0.17	0.8638
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi12	1	0.255148	0.079221	3.22	0.0015
	w12	1	0.124339	0.090881	1.37	0.1730
	lagresi22	1	0.245913	0.079323	3.10	0.0023
	w22	1	0.110824	0.091360	1.21	0.2268
Parameter Estimates						
	Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t
	lagresi13	1	0.391632	0.079218	4.94	<.0001
	w13	1	-0.01807	0.084880	-0.21	0.8316
	lagresi23	1	0.240324	0.079693	3.02	0.0029
	w23	1	0.111238	0.085311	1.30	0.1940

Lampiran 31. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 1 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	2,397	2,318	2,175	2,979	2,658	2,542
GSTARX-FFNN (12,2,1)	2,689	2,490	2,624	3,171	2,606	2,897
GSTARX-FFNN (12,3,1)*	3,157	2,301	2,611	3,026	2,283	2,437
GSTARX-FFNN (12,4,1)	3,134	2,851	2,547	3,816	2,837	2,891
GSTARX-FFNN (12,5,1)	2,826	2,330	2,433	3,233	2,700	2,683
GSTARX-FFNN (12,10,1)	2,700	2,814	2,794	3,074	2,682	2,713
GSTARX-FFNN (12,15,1)	2,694	2,582	3,316	3,126	2,663	2,751
GSTARX-DLNN (12,1,1,1)	2,919	2,755	2,875	3,101	2,850	2,951
GSTARX-DLNN (12,1,2,1)	2,539	2,645	2,175	2,886	2,668	2,588
GSTARX-DLNN (12,1,3,1)	2,656	2,574	2,360	2,992	2,408	2,712
GSTARX-DLNN (12,1,4,1)	2,479	2,507	2,173	2,930	2,512	2,682
GSTARX-DLNN (12,1,5,1)	2,611	2,459	2,323	3,220	2,786	2,888
GSTARX-DLNN (12,2,1,1)	2,722	2,410	2,236	2,973	2,190	2,711
GSTARX-DLNN (12,2,2,1)	2,583	2,516	2,183	2,929	2,331	2,813
GSTARX-DLNN (12,2,3,1)	2,682	2,723	2,319	2,906	2,190	2,661
GSTARX-DLNN (12,2,4,1)	2,740	2,346	2,689	2,945	3,270	2,820
GSTARX-DLNN (12,2,5,1)	2,619	2,759	2,532	3,048	2,775	2,659
GSTARX-DLNN (12,3,1,1)	2,528	2,271	2,276	3,046	2,401	2,747
GSTARX-DLNN (12,3,2,1)	2,541	2,464	2,657	3,086	2,684	2,880
GSTARX-DLNN (12,3,3,1)	2,680	2,589	2,404	3,009	2,857	2,932
GSTARX-DLNN (12,3,4,1)	2,529	2,389	2,524	3,203	2,622	2,905
GSTARX-DLNN (12,3,5,1)	2,658	2,415	2,514	3,109	2,771	3,104
GSTARX-DLNN (12,4,1,1)	2,608	2,680	2,604	3,393	2,527	2,513
GSTARX-DLNN (12,4,2,1)	2,620	2,595	2,783	3,206	2,779	2,619
GSTARX-DLNN (12,4,3,1)	3,126	3,062	2,938	3,145	2,786	3,102
GSTARX-DLNN (12,4,4,1)	2,806	2,665	2,366	3,065	2,869	2,778
GSTARX-DLNN (12,4,5,1)	2,663	2,705	2,834	3,254	2,461	2,698
GSTARX-DLNN (12,5,1,1)	2,717	2,622	2,510	3,142	2,839	2,973
GSTARX-DLNN (12,5,2,1)	2,813	2,410	2,227	2,938	2,619	2,768
GSTARX-DLNN (12,5,3,1)	2,999	2,725	2,440	2,902	2,421	2,524
GSTARX-DLNN (12,5,4,1)	3,050	2,894	3,057	3,097	2,846	2,878
GSTARX-DLNN (12,5,5,1)	3,260	2,553	2,653	3,258	2,786	2,732
GSTARX-DLNN (12,10,1,1)	2,580	2,439	2,896	2,876	2,568	2,523
GSTARX-DLNN (12,10,2,1)	2,715	2,478	2,293	3,211	2,709	3,081
GSTARX-DLNN (12,10,3,1)	2,940	2,531	2,440	3,036	2,320	2,638
GSTARX-DLNN (12,10,4,1)*	2,941	2,653	2,795	2,671	2,025	2,427
GSTARX-DLNN (12,10,5,1)	2,573	2,592	2,541	3,091	2,763	2,862

Lampiran 31. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 1 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,1,1)	2,697	2,595	2,578	3,084	2,652	3,127
GSTARX-DLNN (12,15,2,1)	2,965	2,469	2,867	3,046	2,716	2,868
GSTARX-DLNN (12,15,3,1)	2,648	2,579	2,559	3,169	3,067	2,770
GSTARX-DLNN (12,15,4,1)	2,835	2,734	2,734	3,175	3,006	3,055
GSTARX-DLNN (12,15,5,1)	2,844	2,508	2,369	3,082	2,740	2,934

Ket: *model terbaik

Lampiran 32. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 2 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)*	3,501	3,478	3,540	1,753	1,688	1,572
GSTARX-FFNN (12,2,1)	3,520	3,372	3,126	1,908	1,960	1,614
GSTARX-FFNN (12,3,1)	3,501	3,364	3,214	1,739	1,911	1,584
GSTARX-FFNN (12,4,1)	3,712	3,626	3,532	1,717	1,722	1,590
GSTARX-FFNN (12,5,1)	3,486	3,565	3,511	1,842	1,817	1,558
GSTARX-FFNN (12,10,1)	3,597	3,149	3,272	1,720	1,829	1,740
GSTARX-FFNN (12,15,1)	3,772	3,245	3,191	1,979	1,878	1,572
GSTARX-DLNN (12,1,1,1)	3,573	3,573	3,475	1,791	1,757	1,557
GSTARX-DLNN (12,1,2,1)	3,583	3,581	3,559	1,808	1,712	1,571
GSTARX-DLNN (12,1,3,1)	3,624	3,460	3,451	1,747	1,853	1,572
GSTARX-DLNN (12,1,4,1)	3,459	3,404	3,198	1,865	1,927	1,560
GSTARX-DLNN (12,1,5,1)	3,743	3,637	3,439	1,765	1,902	1,617
GSTARX-DLNN (12,2,1,1)	3,465	3,365	3,324	1,746	1,786	1,568
GSTARX-DLNN (12,2,2,1)	3,644	3,585	3,495	1,782	1,849	1,576
GSTARX-DLNN (12,2,3,1)	3,627	3,559	3,499	1,828	1,747	1,582
GSTARX-DLNN (12,2,4,1)	3,637	3,573	3,377	1,794	1,771	1,603
GSTARX-DLNN (12,2,5,1)	3,438	3,405	3,480	1,758	1,736	1,554
GSTARX-DLNN (12,3,1,1)	3,552	3,645	3,471	1,741	1,775	1,577
GSTARX-DLNN (12,3,2,1)	3,602	3,486	3,323	1,830	1,827	1,595
GSTARX-DLNN (12,3,3,1)	3,618	3,492	3,287	1,759	1,804	1,646
GSTARX-DLNN (12,3,4,1)	3,680	3,526	3,453	1,808	1,845	1,585
GSTARX-DLNN (12,3,5,1)	3,539	3,588	3,621	1,712	1,693	1,563
GSTARX-DLNN (12,4,1,1)	3,682	3,560	3,353	1,819	1,863	1,635
GSTARX-DLNN (12,4,2,1)	3,630	3,580	3,378	1,800	1,854	1,609
GSTARX-DLNN (12,4,3,1)	3,714	3,634	3,513	1,746	1,839	1,548
GSTARX-DLNN (12,4,4,1)	3,633	3,534	3,357	1,795	1,818	1,631
GSTARX-DLNN (12,4,5,1)	3,723	3,550	3,410	1,775	1,805	1,545
GSTARX-DLNN (12,5,1,1)	3,516	3,510	3,477	1,744	1,642	1,555
GSTARX-DLNN (12,5,2,1)	3,661	3,466	3,324	1,690	1,779	1,558
GSTARX-DLNN (12,5,3,1)	3,624	3,514	3,327	1,797	1,885	1,601
GSTARX-DLNN (12,5,4,1)	3,241	3,235	3,062	1,900	1,783	1,621
GSTARX-DLNN (12,5,5,1)	3,745	3,686	3,371	1,783	1,738	1,584
GSTARX-DLNN (12,10,1,1)	3,490	3,416	3,474	1,780	1,740	1,560
GSTARX-DLNN (12,10,2,1)*	3,605	3,780	3,455	1,666	1,613	1,524
GSTARX-DLNN (12,10,3,1)	3,645	3,691	3,486	1,801	1,782	1,564
GSTARX-DLNN (12,10,4,1)	3,458	3,479	3,344	1,770	1,895	1,559
GSTARX-DLNN (12,10,5,1)	3,615	3,560	3,290	1,860	1,798	1,594
GSTARX-DLNN (12,15,1,1)	3,652	3,627	3,391	1,786	1,782	1,566

Lampiran 32. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 2 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	3,605	3,430	3,291	1,739	1,835	1,598
GSTARX-DLNN (12,15,3,1)	3,511	3,277	3,275	1,774	1,846	1,628
GSTARX-DLNN (12,15,4,1)	3,618	3,582	3,542	1,748	1,855	1,578
GSTARX-DLNN (12,15,5,1)	3,726	3,752	3,306	1,750	1,860	1,570

Ket: *model terbaik

Lampiran 33. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 3 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	2,474	2,451	2,214	2,402	1,877	2,022
GSTARX-FFNN (12,2,1)	2,550	2,341	2,350	2,028	1,754	1,564
GSTARX-FFNN (12,3,1)	2,591	2,318	2,285	2,159	1,769	1,785
GSTARX-FFNN (12,4,1)	2,576	2,372	2,277	2,409	2,034	2,324
GSTARX-FFNN (12,5,1)	2,567	2,292	2,209	2,494	1,964	1,865
GSTARX-FFNN (12,10,1)	2,637	2,371	2,147	2,412	2,094	1,957
GSTARX-FFNN (12,15,1)*	2,471	2,440	2,151	1,772	1,304	1,361
GSTARX-DLNN (12,1,1,1)*	2,575	2,334	2,370	2,095	1,773	1,477
GSTARX-DLNN (12,1,2,1)	2,604	2,332	2,371	2,104	1,783	1,497
GSTARX-DLNN (12,1,3,1)	2,517	2,276	2,274	2,311	1,926	2,426
GSTARX-DLNN (12,1,4,1)	2,601	2,327	2,353	2,097	1,776	1,487
GSTARX-DLNN (12,1,5,1)	2,600	2,322	2,267	2,283	1,989	2,140
GSTARX-DLNN (12,2,1,1)	2,549	2,292	2,264	2,238	1,994	1,699
GSTARX-DLNN (12,2,2,1)	2,504	2,353	2,203	2,591	2,272	1,838
GSTARX-DLNN (12,2,3,1)	2,539	2,237	2,125	2,531	2,051	1,928
GSTARX-DLNN (12,2,4,1)	2,639	2,397	2,357	2,726	1,808	1,644
GSTARX-DLNN (12,2,5,1)	2,601	2,369	2,200	2,202	2,016	1,756
GSTARX-DLNN (12,3,1,1)	2,473	2,346	2,217	2,259	1,797	1,939
GSTARX-DLNN (12,3,2,1)	2,567	2,360	2,298	2,226	2,055	1,839
GSTARX-DLNN (12,3,3,1)	2,601	2,265	2,341	2,073	1,827	1,508
GSTARX-DLNN (12,3,4,1)	2,466	2,387	2,360	2,241	1,876	1,702
GSTARX-DLNN (12,3,5,1)	2,523	2,342	2,197	2,167	1,807	1,782
GSTARX-DLNN (12,4,1,1)	2,566	2,292	2,199	2,194	1,871	1,739
GSTARX-DLNN (12,4,2,1)	2,484	2,293	2,367	2,274	1,759	1,982
GSTARX-DLNN (12,4,3,1)	2,509	2,421	2,312	2,243	1,931	1,775
GSTARX-DLNN (12,4,4,1)	2,639	2,314	2,185	2,210	1,988	1,938
GSTARX-DLNN (12,4,5,1)	2,415	2,565	2,180	2,491	2,210	1,646
GSTARX-DLNN (12,5,1,1)	2,611	2,395	2,252	2,115	1,832	1,711
GSTARX-DLNN (12,5,2,1)	2,539	2,325	2,246	2,181	1,910	1,759
GSTARX-DLNN (12,5,3,1)	2,638	2,337	2,272	2,453	2,150	1,942
GSTARX-DLNN (12,5,4,1)	2,583	2,333	2,274	2,443	2,167	1,859
GSTARX-DLNN (12,5,5,1)	2,410	2,306	2,280	2,418	2,432	1,912
GSTARX-DLNN (12,10,1,1)	2,478	2,234	2,219	2,259	2,044	1,959
GSTARX-DLNN (12,10,2,1)	2,661	2,312	2,382	2,152	1,848	1,643
GSTARX-DLNN (12,10,3,1)	2,438	2,407	2,222	2,184	1,867	1,869
GSTARX-DLNN (12,10,4,1)	2,518	2,228	2,268	2,305	2,027	1,867
GSTARX-DLNN (12,10,5,1)	2,547	2,365	2,234	2,419	2,146	1,931
GSTARX-DLNN (12,15,1,1)	2,597	2,325	2,294	2,122	1,838	1,912

Lampiran 33. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 3 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	2,625	2,340	2,256	2,255	1,893	1,896
GSTARX-DLNN (12,15,3,1)	2,415	2,310	2,233	2,308	1,950	1,865
GSTARX-DLNN (12,15,4,1)	2,542	2,275	2,198	2,517	2,086	1,891
GSTARX-DLNN (12,15,5,1)	2,578	2,332	2,253	2,326	2,101	2,103

Ket: *model terbaik

Lampiran 34. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 4 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	2,282	2,288	2,156	2,925	2,516	2,814
GSTARX-FFNN (12,2,1)*	2,456	2,217	2,003	2,544	1,953	2,345
GSTARX-FFNN (12,3,1)	2,221	2,311	1,978	2,715	2,243	2,462
GSTARX-FFNN (12,4,1)	2,242	2,217	2,249	2,639	2,184	2,770
GSTARX-FFNN (12,5,1)	2,329	2,171	2,066	2,914	2,473	3,048
GSTARX-FFNN (12,10,1)	2,357	2,176	1,977	3,091	2,328	2,776
GSTARX-FFNN (12,15,1)	2,281	2,271	2,086	2,898	2,381	2,655
GSTARX-DLNN (12,1,1,1)	2,267	2,292	2,095	2,821	2,398	2,465
GSTARX-DLNN (12,1,2,1)	2,391	2,240	2,016	3,047	2,477	2,601
GSTARX-DLNN (12,1,3,1)	2,230	2,344	1,976	3,112	2,410	2,782
GSTARX-DLNN (12,1,4,1)	2,251	2,270	1,997	3,035	2,501	2,692
GSTARX-DLNN (12,1,5,1)	2,271	2,238	2,147	2,929	2,468	2,861
GSTARX-DLNN (12,2,1,1)	2,350	2,194	2,137	3,073	2,692	2,843
GSTARX-DLNN (12,2,2,1)	2,279	2,311	2,022	2,955	2,574	2,562
GSTARX-DLNN (12,2,3,1)	2,233	2,197	1,996	3,018	2,446	2,735
GSTARX-DLNN (12,2,4,1)	2,256	2,207	2,209	2,900	2,362	2,874
GSTARX-DLNN (12,2,5,1)	2,204	2,220	1,930	3,202	2,695	2,632
GSTARX-DLNN (12,3,1,1)	2,289	2,365	1,995	2,566	1,884	2,392
GSTARX-DLNN (12,3,2,1)	2,285	2,336	2,066	2,972	2,411	2,864
GSTARX-DLNN (12,3,3,1)	2,154	2,390	2,007	2,481	2,215	2,701
GSTARX-DLNN (12,3,4,1)	2,333	2,315	2,038	3,166	2,169	2,781
GSTARX-DLNN (12,3,5,1)	2,349	2,272	2,015	3,187	2,494	2,808
GSTARX-DLNN (12,4,1,1)	2,333	2,291	2,003	2,792	2,379	2,736
GSTARX-DLNN (12,4,2,1)	2,232	2,304	1,977	2,817	2,396	2,636
GSTARX-DLNN (12,4,3,1)	2,207	2,399	2,043	2,654	2,268	2,578
GSTARX-DLNN (12,4,4,1)	2,365	2,412	1,988	2,689	2,270	2,426
GSTARX-DLNN (12,4,5,1)	2,285	2,253	2,076	2,782	1,888	2,495
GSTARX-DLNN (12,5,1,1)	2,463	2,238	2,168	3,076	2,507	2,807
GSTARX-DLNN (12,5,2,1)	2,280	2,199	2,085	3,003	2,681	2,549
GSTARX-DLNN (12,5,3,1)*	2,372	2,171	2,183	2,086	1,645	2,305
GSTARX-DLNN (12,5,4,1)	2,221	2,179	2,021	3,196	2,430	2,753
GSTARX-DLNN (12,5,5,1)	2,339	2,287	1,988	2,979	2,433	2,678
GSTARX-DLNN (12,10,1,1)	2,251	2,215	2,016	2,847	2,479	2,773
GSTARX-DLNN (12,10,2,1)	2,334	2,207	1,961	2,927	2,481	2,633
GSTARX-DLNN (12,10,3,1)	2,169	2,450	1,891	2,595	2,310	2,724
GSTARX-DLNN (12,10,4,1)	2,334	2,289	2,081	3,260	2,531	2,793
GSTARX-DLNN (12,10,5,1)	2,250	2,356	1,996	3,167	2,253	2,694
GSTARX-DLNN (12,15,1,1)	2,329	2,231	2,011	3,085	2,487	2,632

Lampiran 34. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 4 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	2,223	2,413	2,065	2,583	2,370	2,612
GSTARX-DLNN (12,15,3,1)	2,319	2,396	1,917	2,434	2,046	2,449
GSTARX-DLNN (12,15,4,1)	2,307	2,248	2,005	2,940	2,513	2,939
GSTARX-DLNN (12,15,5,1)	2,298	2,283	2,024	2,817	2,242	2,637

Ket: *model terbaik

Lampiran 35. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 5 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	3,090	2,245	2,001	1,899	2,399	1,342
GSTARX-FFNN (12,2,1)	2,840	2,394	2,022	1,899	2,297	1,361
GSTARX-FFNN (12,3,1)	2,845	2,258	2,022	1,865	2,363	1,455
GSTARX-FFNN (12,4,1)	3,035	2,383	2,084	1,791	2,149	1,272
GSTARX-FFNN (12,5,1)	2,738	2,489	2,188	1,789	2,033	1,388
GSTARX-FFNN (12,10,1)	2,949	2,509	1,837	1,974	2,336	1,329
GSTARX-FFNN (12,15,1)*	2,947	2,313	1,983	1,732	2,176	1,101
GSTARX-DLNN (12,1,1,1)	2,990	2,274	1,991	1,841	2,394	1,298
GSTARX-DLNN (12,1,2,1)	2,808	2,333	1,975	1,907	2,365	1,327
GSTARX-DLNN (12,1,3,1)	2,833	2,489	2,083	1,940	2,376	1,502
GSTARX-DLNN (12,1,4,1)	2,882	2,512	1,935	1,919	2,314	1,552
GSTARX-DLNN (12,1,5,1)	2,665	2,381	2,021	2,014	2,394	1,368
GSTARX-DLNN (12,2,1,1)	2,811	2,403	2,196	1,965	2,355	1,491
GSTARX-DLNN (12,2,2,1)	2,736	2,487	2,145	1,967	2,413	1,508
GSTARX-DLNN (12,2,3,1)	2,794	2,456	2,116	1,979	2,338	1,532
GSTARX-DLNN (12,2,4,1)	2,913	2,325	2,026	1,902	2,333	1,433
GSTARX-DLNN (12,2,5,1)	2,978	2,213	1,986	1,866	2,343	1,337
GSTARX-DLNN (12,3,1,1)	2,955	2,287	1,954	1,884	2,468	1,447
GSTARX-DLNN (12,3,2,1)	2,647	2,515	2,041	2,017	2,358	1,414
GSTARX-DLNN (12,3,3,1)	2,823	2,479	2,053	1,946	2,327	1,464
GSTARX-DLNN (12,3,4,1)	2,988	2,304	2,063	1,878	2,417	1,490
GSTARX-DLNN (12,3,5,1)	2,872	2,484	2,051	2,017	2,425	1,461
GSTARX-DLNN (12,4,1,1)	2,971	2,303	2,090	1,915	2,398	1,364
GSTARX-DLNN (12,4,2,1)	2,838	2,318	2,074	1,999	2,368	1,389
GSTARX-DLNN (12,4,3,1)	3,171	2,245	1,987	1,730	2,308	1,344
GSTARX-DLNN (12,4,4,1)	2,749	2,408	1,925	1,888	2,289	1,455
GSTARX-DLNN (12,4,5,1)	2,985	2,343	2,033	1,832	2,294	1,444
GSTARX-DLNN (12,5,1,1)	3,040	2,253	1,946	1,899	2,381	1,489
GSTARX-DLNN (12,5,2,1)	3,001	2,285	2,029	1,977	2,387	1,303
GSTARX-DLNN (12,5,3,1)	2,974	2,244	2,003	1,897	2,283	1,362
GSTARX-DLNN (12,5,4,1)	3,050	2,220	1,991	1,804	2,355	1,517
GSTARX-DLNN (12,5,5,1)	3,069	2,248	1,949	1,907	2,330	1,462
GSTARX-DLNN (12,10,1,1)	2,966	2,304	2,045	1,857	2,390	1,295
GSTARX-DLNN (12,10,2,1)*	3,030	2,242	1,962	1,790	2,241	1,155
GSTARX-DLNN (12,10,3,1)	2,648	2,357	2,357	2,001	2,351	1,569
GSTARX-DLNN (12,10,4,1)	2,968	2,353	2,115	1,851	2,306	1,346
GSTARX-DLNN (12,10,5,1)	2,945	2,282	2,056	1,908	2,415	1,599
GSTARX-DLNN (12,15,1,1)	2,560	2,448	1,881	1,966	2,392	1,508

Lampiran 35. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 5 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	3,022	2,329	1,922	1,874	2,447	1,420
GSTARX-DLNN (12,15,3,1)	2,770	2,489	1,910	1,918	2,361	1,416
GSTARX-DLNN (12,15,4,1)	2,891	2,491	2,060	1,963	2,399	1,352
GSTARX-DLNN (12,15,5,1)	2,649	2,259	2,125	1,925	2,432	1,450

Ket: *model terbaik

Lampiran 36. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 6 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	3,009	2,891	2,687	1,793	1,376	1,796
GSTARX-FFNN (12,2,1)	3,227	2,754	2,838	1,720	1,189	1,896
GSTARX-FFNN (12,3,1)	3,484	2,471	2,584	1,753	1,484	1,785
GSTARX-FFNN (12,4,1)	2,891	3,285	2,752	2,028	1,169	1,976
GSTARX-FFNN (12,5,1)*	2,789	2,597	3,259	1,704	1,159	1,680
GSTARX-FFNN (12,10,1)	2,799	2,726	2,858	1,730	1,602	1,743
GSTARX-FFNN (12,15,1)	3,174	2,521	2,821	2,038	1,600	1,819
GSTARX-DLNN (12,1,1,1)	3,001	2,836	2,893	1,817	1,324	1,743
GSTARX-DLNN (12,1,2,1)	3,063	2,841	2,751	1,801	1,413	1,777
GSTARX-DLNN (12,1,3,1)	3,119	2,694	2,802	1,798	1,362	1,746
GSTARX-DLNN (12,1,4,1)	3,049	2,793	2,656	1,789	1,435	1,781
GSTARX-DLNN (12,1,5,1)	3,105	2,879	2,771	1,784	1,410	1,788
GSTARX-DLNN (12,2,1,1)	3,018	2,823	2,713	1,861	1,318	1,760
GSTARX-DLNN (12,2,2,1)	3,120	2,788	2,697	1,772	1,450	1,779
GSTARX-DLNN (12,2,3,1)	2,978	2,686	3,002	1,705	1,267	1,681
GSTARX-DLNN (12,2,4,1)	2,813	2,625	2,844	1,827	1,382	1,702
GSTARX-DLNN (12,2,5,1)	2,913	2,627	2,942	1,766	1,302	1,744
GSTARX-DLNN (12,3,1,1)	3,103	2,753	2,802	1,728	1,376	1,693
GSTARX-DLNN (12,3,2,1)	3,042	2,662	3,060	1,694	1,243	1,706
GSTARX-DLNN (12,3,3,1)	3,187	2,740	2,846	1,748	1,316	1,733
GSTARX-DLNN (12,3,4,1)	3,064	2,721	2,737	1,786	1,453	1,797
GSTARX-DLNN (12,3,5,1)	3,165	2,873	2,822	1,726	1,380	1,784
GSTARX-DLNN (12,4,1,1)	3,191	2,744	2,661	1,740	1,412	1,770
GSTARX-DLNN (12,4,2,1)	3,096	2,733	2,913	1,792	1,304	1,702
GSTARX-DLNN (12,4,3,1)	2,984	2,581	2,897	1,770	1,275	1,673
GSTARX-DLNN (12,4,4,1)	2,918	2,889	2,818	1,812	1,399	1,748
GSTARX-DLNN (12,4,5,1)	3,020	2,798	3,039	1,655	1,312	1,721
GSTARX-DLNN (12,5,1,1)	3,049	2,343	2,694	1,655	1,496	1,762
GSTARX-DLNN (12,5,2,1)	3,071	2,846	2,863	1,785	1,290	1,710
GSTARX-DLNN (12,5,3,1)	2,913	2,778	3,013	1,745	1,219	1,737
GSTARX-DLNN (12,5,4,1)	2,977	2,918	2,609	1,804	1,285	1,819
GSTARX-DLNN (12,5,5,1)	3,452	2,649	2,800	1,748	1,240	1,760
GSTARX-DLNN (12,10,1,1)	3,222	2,803	2,721	1,748	1,318	1,860
GSTARX-DLNN (12,10,2,1)	2,977	2,694	3,002	1,792	1,239	1,747
GSTARX-DLNN (12,10,3,1)	3,245	2,663	2,786	1,744	1,498	1,877
GSTARX-DLNN (12,10,4,1)	2,964	2,794	2,970	1,775	1,378	1,703
GSTARX-DLNN (12,10,5,1)	2,913	2,496	3,164	1,787	1,270	1,725
GSTARX-DLNN (12,15,1,1)	2,963	2,735	2,877	1,824	1,320	1,776

Lampiran 36. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 6 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)*	3,488	2,903	2,759	1,593	1,037	1,877
GSTARX-DLNN (12,15,3,1)	3,194	2,724	2,894	1,759	1,215	1,746
GSTARX-DLNN (12,15,4,1)	3,078	2,923	2,955	1,664	1,215	1,794
GSTARX-DLNN (12,15,5,1)	2,901	2,883	2,734	1,798	1,587	1,828

Ket: *model terbaik

Lampiran 37. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 7 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	3,063	2,904	2,657	1,689	1,640	1,269
GSTARX-FFNN (12,2,1)	2,986	2,794	2,583	1,567	1,747	1,229
GSTARX-FFNN (12,3,1)*	3,185	3,218	2,664	1,257	1,199	1,250
GSTARX-FFNN (12,4,1)	3,045	2,864	2,625	1,621	1,676	1,652
GSTARX-FFNN (12,5,1)	3,165	3,104	2,722	1,494	1,447	1,343
GSTARX-FFNN (12,10,1)	2,979	2,895	2,770	1,778	2,047	1,815
GSTARX-FFNN (12,15,1)	2,739	3,090	2,776	1,894	1,614	1,667
GSTARX-DLNN (12,1,1,1)	3,011	2,961	2,857	1,599	1,566	1,003
GSTARX-DLNN (12,1,2,1)	3,104	3,189	2,671	1,601	1,587	1,213
GSTARX-DLNN (12,1,3,1)	3,116	2,985	2,771	1,731	1,539	1,428
GSTARX-DLNN (12,1,4,1)	2,977	2,818	2,708	1,691	1,752	1,592
GSTARX-DLNN (12,1,5,1)	2,804	2,839	2,617	1,854	1,822	1,469
GSTARX-DLNN (12,2,1,1)	2,879	3,007	3,000	1,607	1,660	0,961
GSTARX-DLNN (12,2,2,1)	2,907	2,874	2,677	1,650	1,686	1,083
GSTARX-DLNN (12,2,3,1)	3,017	2,922	2,567	1,580	1,640	1,407
GSTARX-DLNN (12,2,4,1)	3,064	2,808	2,713	1,453	1,348	1,179
GSTARX-DLNN (12,2,5,1)	2,937	3,116	2,741	1,607	1,465	1,571
GSTARX-DLNN (12,3,1,1)	3,094	3,077	2,632	1,581	1,150	1,450
GSTARX-DLNN (12,3,2,1)	3,025	2,956	2,740	1,676	1,598	1,451
GSTARX-DLNN (12,3,3,1)	2,958	2,869	2,441	1,594	1,690	1,695
GSTARX-DLNN (12,3,4,1)	2,978	2,888	2,635	1,672	1,568	1,694
GSTARX-DLNN (12,3,5,1)	3,014	2,889	2,575	1,646	1,492	1,464
GSTARX-DLNN (12,4,1,1)	3,117	3,056	2,706	1,735	1,619	1,298
GSTARX-DLNN (12,4,2,1)	3,030	2,869	2,738	1,592	1,686	1,368
GSTARX-DLNN (12,4,3,1)	3,008	2,694	2,681	1,542	1,692	1,599
GSTARX-DLNN (12,4,4,1)	3,139	3,068	2,669	1,635	1,102	1,355
GSTARX-DLNN (12,4,5,1)	3,112	2,871	2,479	1,363	1,227	1,337
GSTARX-DLNN (12,5,1,1)	3,110	2,896	2,658	1,448	1,641	1,372
GSTARX-DLNN (12,5,2,1)	2,953	3,008	2,658	1,682	1,625	1,301
GSTARX-DLNN (12,5,3,1)	2,993	2,789	2,567	1,714	1,696	1,400
GSTARX-DLNN (12,5,4,1)	3,113	2,977	2,561	1,402	1,324	1,191
GSTARX-DLNN (12,5,5,1)	3,022	2,912	2,458	1,486	1,609	1,322
GSTARX-DLNN (12,10,1,1)	3,027	2,975	2,761	1,625	1,429	1,545
GSTARX-DLNN (12,10,2,1)	3,082	3,062	2,545	1,595	1,488	1,309
GSTARX-DLNN (12,10,3,1)	3,088	3,149	2,476	1,375	1,063	1,300
GSTARX-DLNN (12,10,4,1)	3,022	2,938	2,587	1,546	1,438	1,181
GSTARX-DLNN (12,10,5,1)	3,002	3,068	2,646	1,555	1,210	1,691
GSTARX-DLNN (12,15,1,1)	3,125	3,060	2,603	1,661	1,675	1,379

Lampiran 37. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 7 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	3,026	3,076	2,613	1,655	1,531	1,587
GSTARX-DLNN (12,15,3,1)	3,099	2,987	2,710	1,582	1,536	1,533
GSTARX-DLNN (12,15,4,1)	3,004	2,731	2,643	1,575	1,581	1,303
GSTARX-DLNN (12,15,5,1)*	2,936	2,805	2,280	1,154	1,085	0,914

Ket: *model terbaik

Lampiran 38. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 8 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	2,424	2,128	2,189	2,743	2,670	3,006
GSTARX-FFNN (12,2,1)	2,518	2,185	2,169	2,880	2,705	3,193
GSTARX-FFNN (12,3,1)	2,443	2,123	2,264	2,939	2,526	2,795
GSTARX-FFNN (12,4,1)*	2,498	2,149	2,149	2,717	2,670	2,864
GSTARX-FFNN (12,5,1)	2,377	2,146	2,036	2,971	2,852	3,017
GSTARX-FFNN (12,10,1)	2,429	2,125	2,087	2,750	2,789	3,239
GSTARX-FFNN (12,15,1)	2,412	2,109	2,138	2,709	2,600	3,099
GSTARX-DLNN (12,1,1,1)	2,460	2,139	2,171	2,690	2,634	3,033
GSTARX-DLNN (12,1,2,1)	2,313	2,183	2,233	2,940	2,952	2,840
GSTARX-DLNN (12,1,3,1)	2,463	2,204	2,346	2,662	2,697	2,999
GSTARX-DLNN (12,1,4,1)	2,494	2,101	2,130	3,076	2,797	3,040
GSTARX-DLNN (12,1,5,1)	2,378	2,133	2,091	2,980	2,690	3,065
GSTARX-DLNN (12,2,1,1)	2,571	2,257	2,198	2,713	2,614	2,954
GSTARX-DLNN (12,2,2,1)	2,572	2,199	2,162	2,897	2,694	3,226
GSTARX-DLNN (12,2,3,1)	2,432	2,183	2,114	2,769	2,670	3,042
GSTARX-DLNN (12,2,4,1)	2,289	2,150	2,094	2,924	2,963	3,028
GSTARX-DLNN (12,2,5,1)	2,401	2,351	2,087	2,808	2,892	3,042
GSTARX-DLNN (12,3,1,1)	2,414	2,117	2,174	2,736	2,672	3,164
GSTARX-DLNN (12,3,2,1)	2,359	2,093	2,033	2,966	2,495	3,090
GSTARX-DLNN (12,3,3,1)	2,307	1,998	2,053	3,046	2,465	2,929
GSTARX-DLNN (12,3,4,1)	2,312	2,011	2,016	3,190	2,850	3,061
GSTARX-DLNN (12,3,5,1)	2,317	2,180	2,099	2,689	2,693	2,903
GSTARX-DLNN (12,4,1,1)	2,456	2,155	2,164	2,712	2,471	2,910
GSTARX-DLNN (12,4,2,1)*	2,497	2,173	2,230	2,395	2,520	2,548
GSTARX-DLNN (12,4,3,1)	2,525	2,149	2,087	2,701	2,518	2,966
GSTARX-DLNN (12,4,4,1)	2,543	2,239	1,966	2,538	2,556	3,069
GSTARX-DLNN (12,4,5,1)	2,308	2,094	2,034	2,954	2,916	3,000
GSTARX-DLNN (12,5,1,1)	2,362	2,170	2,069	2,876	2,848	3,058
GSTARX-DLNN (12,5,2,1)	2,281	2,113	2,133	2,939	2,865	2,873
GSTARX-DLNN (12,5,3,1)	2,287	2,124	2,077	2,818	2,922	3,192
GSTARX-DLNN (12,5,4,1)	2,412	2,306	2,178	2,798	2,718	3,067
GSTARX-DLNN (12,5,5,1)	2,441	2,208	2,054	2,757	2,735	2,905
GSTARX-DLNN (12,10,1,1)	2,419	2,299	2,025	2,849	2,849	3,086
GSTARX-DLNN (12,10,2,1)	2,499	2,196	2,138	2,648	2,836	3,117
GSTARX-DLNN (12,10,3,1)	2,477	2,219	2,025	2,947	3,093	3,259
GSTARX-DLNN (12,10,4,1)	2,400	2,133	2,362	3,138	2,815	3,341
GSTARX-DLNN (12,10,5,1)	2,368	2,127	1,998	3,028	2,593	3,048
GSTARX-DLNN (12,15,1,1)	2,457	2,105	2,056	2,854	2,995	3,136

Lampiran 38. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 8 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	2,272	2,121	1,963	3,047	2,750	2,970
GSTARX-DLNN (12,15,3,1)	2,308	2,083	2,076	2,887	2,773	3,282
GSTARX-DLNN (12,15,4,1)	2,375	2,115	2,022	3,097	2,855	3,054
GSTARX-DLNN (12,15,5,1)	2,291	2,069	2,018	2,857	2,873	3,250

Ket: *model terbaik

Lampiran 39. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 9 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	3,175	3,103	2,871	1,864	2,108	2,135
GSTARX-FFNN (12,2,1)	3,270	3,057	2,903	1,973	1,994	2,213
GSTARX-FFNN (12,3,1)	3,087	3,146	2,757	1,882	2,108	2,139
GSTARX-FFNN (12,4,1)	3,258	3,225	3,112	1,742	1,991	2,069
GSTARX-FFNN (12,5,1)	3,340	3,308	3,021	2,068	2,015	1,992
GSTARX-FFNN (12,10,1)	3,237	2,492	2,985	2,267	2,186	2,193
GSTARX-FFNN (12,15,1)*	3,647	2,846	3,476	1,756	1,911	2,063
GSTARX-DLNN (12,1,1,1)	3,070	2,984	3,035	1,878	2,000	1,924
GSTARX-DLNN (12,1,2,1)	3,127	3,079	2,900	1,880	2,088	2,119
GSTARX-DLNN (12,1,3,1)	3,094	3,046	2,890	1,876	2,078	2,131
GSTARX-DLNN (12,1,4,1)	3,183	2,955	3,018	1,896	2,143	2,042
GSTARX-DLNN (12,1,5,1)	3,128	3,039	2,861	1,890	2,119	2,124
GSTARX-DLNN (12,2,1,1)	3,114	3,005	2,852	1,893	2,129	2,118
GSTARX-DLNN (12,2,2,1)	3,201	3,117	2,919	1,873	2,071	2,125
GSTARX-DLNN (12,2,3,1)	3,209	3,080	2,881	1,873	2,111	2,085
GSTARX-DLNN (12,2,4,1)	3,227	3,018	2,907	1,815	2,060	2,148
GSTARX-DLNN (12,2,5,1)	2,869	2,861	2,868	1,917	2,122	2,072
GSTARX-DLNN (12,3,1,1)	3,175	3,082	2,906	1,869	2,103	2,126
GSTARX-DLNN (12,3,2,1)	3,174	3,095	2,983	1,877	2,085	2,035
GSTARX-DLNN (12,3,3,1)	3,136	3,056	2,871	1,955	1,976	2,096
GSTARX-DLNN (12,3,4,1)	3,322	3,038	3,030	1,876	2,155	2,059
GSTARX-DLNN (12,3,5,1)	3,392	3,029	3,269	1,862	1,952	1,955
GSTARX-DLNN (12,4,1,1)	3,133	3,051	2,938	1,875	2,135	2,096
GSTARX-DLNN (12,4,2,1)	3,152	3,122	3,093	1,894	1,991	2,020
GSTARX-DLNN (12,4,3,1)	2,935	3,094	2,941	1,897	2,002	2,051
GSTARX-DLNN (12,4,4,1)	3,190	2,941	2,953	1,874	2,034	1,971
GSTARX-DLNN (12,4,5,1)	3,121	3,283	3,120	1,819	2,128	1,967
GSTARX-DLNN (12,5,1,1)	3,031	2,937	2,954	1,871	2,051	2,061
GSTARX-DLNN (12,5,2,1)	3,156	3,029	3,035	1,858	2,106	2,086
GSTARX-DLNN (12,5,3,1)	3,132	3,013	2,846	1,922	2,110	2,072
GSTARX-DLNN (12,5,4,1)	3,127	3,152	2,892	1,821	1,963	2,193
GSTARX-DLNN (12,5,5,1)	3,394	3,375	3,044	1,916	1,799	1,950
GSTARX-DLNN (12,10,1,1)	3,162	3,068	2,906	1,868	2,115	2,110
GSTARX-DLNN (12,10,2,1)	3,162	3,158	3,030	1,851	2,143	2,069
GSTARX-DLNN (12,10,3,1)	3,162	3,069	2,857	1,875	2,100	2,147
GSTARX-DLNN (12,10,4,1)	3,194	3,101	3,029	1,963	1,946	2,034
GSTARX-DLNN (12,10,5,1)	3,107	2,912	2,735	2,101	2,111	2,088
GSTARX-DLNN (12,15,1,1)	3,061	3,112	2,856	1,874	1,985	2,138

Lampiran 39. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 9 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	2,912	3,130	3,031	1,880	1,934	1,986
GSTARX-DLNN (12,15,3,1)	3,076	3,249	2,880	1,853	1,885	2,047
GSTARX-DLNN (12,15,4,1)	3,183	3,134	3,094	1,869	2,144	2,080
GSTARX-DLNN (12,15,5,1)*	3,473	3,182	3,320	1,710	1,866	1,867

Ket: *model terbaik

Lampiran 40. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 10 Skenario II

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-FFNN (12,1,1)	2,354	2,311	2,465	1,614	1,343	1,841
GSTARX-FFNN (12,2,1)*	2,781	2,286	2,146	1,380	1,289	2,018
GSTARX-FFNN (12,3,1)	2,787	2,275	2,458	1,469	1,331	1,995
GSTARX-FFNN (12,4,1)	2,781	2,225	2,288	1,369	1,389	1,948
GSTARX-FFNN (12,5,1)	2,544	2,222	2,213	1,392	1,422	1,894
GSTARX-FFNN (12,10,1)	2,620	2,234	2,302	1,546	1,231	2,007
GSTARX-FFNN (12,15,1)	2,606	2,273	2,190	1,490	1,472	1,967
GSTARX-DLNN (12,1,1,1)	2,503	2,283	2,097	1,544	1,281	2,176
GSTARX-DLNN (12,1,2,1)	2,532	2,481	2,173	1,418	1,452	2,070
GSTARX-DLNN (12,1,3,1)	2,303	2,166	2,094	1,611	1,579	2,166
GSTARX-DLNN (12,1,4,1)	2,429	2,246	2,286	1,874	1,472	1,981
GSTARX-DLNN (12,1,5,1)	2,340	2,330	2,357	1,704	1,266	1,891
GSTARX-DLNN (12,2,1,1)	2,645	2,343	2,195	1,317	1,191	1,870
GSTARX-DLNN (12,2,2,1)	2,483	2,268	2,037	1,509	1,169	2,031
GSTARX-DLNN (12,2,3,1)	2,357	2,322	2,296	1,514	1,463	1,897
GSTARX-DLNN (12,2,4,1)	2,446	2,401	2,555	1,665	1,147	1,973
GSTARX-DLNN (12,2,5,1)	2,602	2,388	2,302	1,598	1,246	1,739
GSTARX-DLNN (12,3,1,1)	2,741	2,283	2,191	1,418	1,340	2,074
GSTARX-DLNN (12,3,2,1)	2,507	2,354	2,243	1,638	1,263	1,956
GSTARX-DLNN (12,3,3,1)	2,753	2,329	2,063	1,509	1,300	2,227
GSTARX-DLNN (12,3,4,1)	2,496	2,251	2,495	1,463	1,292	1,821
GSTARX-DLNN (12,3,5,1)	2,366	2,319	2,566	1,484	1,262	1,884
GSTARX-DLNN (12,4,1,1)	2,475	2,370	2,225	1,557	1,372	1,830
GSTARX-DLNN (12,4,2,1)	2,446	2,262	2,124	1,470	1,323	1,858
GSTARX-DLNN (12,4,3,1)	2,632	2,397	2,297	1,401	1,218	1,911
GSTARX-DLNN (12,4,4,1)	2,684	2,279	2,240	1,438	1,358	2,018
GSTARX-DLNN (12,4,5,1)	2,770	2,286	2,387	1,451	1,248	1,813
GSTARX-DLNN (12,5,1,1)	2,645	2,320	2,358	1,403	1,151	1,811
GSTARX-DLNN (12,5,2,1)	2,506	2,368	2,404	1,500	1,319	1,926
GSTARX-DLNN (12,5,3,1)*	2,754	2,415	2,011	1,324	1,106	1,760
GSTARX-DLNN (12,5,4,1)	2,563	2,388	2,490	1,663	1,358	1,980
GSTARX-DLNN (12,5,5,1)	2,524	2,366	2,580	1,688	1,447	2,091
GSTARX-DLNN (12,10,1,1)	2,598	2,300	2,215	1,378	1,246	1,815
GSTARX-DLNN (12,10,2,1)	2,673	2,316	2,204	1,350	1,181	1,815
GSTARX-DLNN (12,10,3,1)	2,498	2,402	2,250	1,762	1,166	1,835
GSTARX-DLNN (12,10,4,1)	2,670	2,293	2,200	1,512	1,356	2,041
GSTARX-DLNN (12,10,5,1)	2,553	2,306	2,142	1,296	1,343	1,962
GSTARX-DLNN (12,15,1,1)	2,631	2,126	2,169	1,466	1,327	1,837

Lampiran 40. Nilai RMSE Model *hybrid* GSTARX-ANN Simulasi 10 Skenario II (lanjutan)

Model	RMSE in Sample			RMSE out Sample		
	Lokasi 1	Lokasi 2	Lokasi 3	Lokasi 1	Lokasi 2	Lokasi 3
GSTARX-DLNN (12,15,2,1)	2,661	2,236	2,253	1,396	1,228	1,961
GSTARX-DLNN (12,15,3,1)	2,640	2,435	2,211	1,317	1,272	1,775
GSTARX-DLNN (12,15,4,1)	2,532	2,255	2,309	1,550	1,375	2,062
GSTARX-DLNN (12,15,5,1)	2,416	2,206	2,301	1,586	1,309	1,972

Ket: *model terbaik

Lampiran 41. Nilai RMSE Data *Inflow* Model *hybrid* GSTARX-FFNN

Model (bobot Seragam)	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-FFNN (8,1,1)	482,569	172,393	154,091	97,628	1064,455	473,974	445,930	196,944
GSTARX-FFNN (8,2,1)	482,369	172,507	153,845	97,686	1063,729	472,198	444,260	196,290
GSTARX-FFNN (8,3,1)	478,167	173,237	153,416	103,466	1042,499	474,693	446,626	195,263
GSTARX-FFNN (8,4,1)	481,867	172,737	154,866	97,579	1062,777	476,903	449,172	195,372
GSTARX-FFNN (8,5,1)	471,511	174,089	153,274	98,105	1034,639	482,186	432,244	191,190
GSTARX-FFNN (8,10,1)	466,327	176,805	158,555	104,037	1025,432	492,515	441,623	205,087
GSTARX-FFNN (8,15,1)*	481,716	173,181	154,309	116,183	1068,463	443,579	423,480	176,953
Ket: *model terbaik								
Model (bobot Invers Jarak)	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-FFNN (8,1,1)	482,571	172,393	154,081	97,631	1064,457	474,036	445,867	196,926
GSTARX-FFNN (8,2,1)*	468,632	174,128	153,660	97,732	1012,201	457,174	417,874	189,555
GSTARX-FFNN (8,3,1)	473,058	171,599	156,548	98,961	1051,945	476,100	440,818	206,923
GSTARX-FFNN (8,4,1)	481,649	172,710	154,938	97,554	1060,619	477,578	450,470	194,800
GSTARX-FFNN (8,5,1)	470,074	174,510	153,279	97,957	1033,045	482,274	432,586	192,037
GSTARX-FFNN (8,10,1)	464,634	176,828	158,781	104,170	1023,275	492,434	440,147	204,053
GSTARX-FFNN (8,15,1)	479,692	173,402	154,293	117,337	1062,645	444,242	423,596	180,854
Ket: *model terbaik								
Model (bobot NIKSP)	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-FFNN (8,1,1)	482,568	172,394	154,105	97,643	1064,434	473,923	446,581	197,360
GSTARX-FFNN (8,2,1)	481,173	173,025	155,267	97,481	1063,537	474,561	445,996	197,154
GSTARX-FFNN (8,3,1)	482,504	172,415	154,222	97,534	1064,825	473,644	445,305	195,828
GSTARX-FFNN (8,4,1)	481,829	172,593	154,366	97,082	1063,723	474,132	443,773	189,697
GSTARX-FFNN (8,5,1)*	479,037	174,368	162,947	106,446	1042,723	467,863	435,097	184,984
GSTARX-FFNN (8,10,1)	471,539	180,102	151,307	105,715	1040,256	479,470	433,634	198,087
GSTARX-FFNN (8,15,1)	484,915	174,804	158,925	109,682	1081,018	457,167	410,335	215,965

Lampiran 42. Estimasi Parameter Model *hybrid* GSTAR-FFNN(8,2,1) Bobot Invers Jarak Data

Inflow

Predictor		Predicted		
		Hidden Layer 1		Output Layer
		H(1:1)	H(1:2)	Nt
Input Layer	(Bias)	-,377	-,321	
	N1t_1	,490	-,378	
	N2t_1	-,215	,299	
	N3t_1	-,141	,515	
	N4t_1	-,115	,310	
	W1t_1	-,614	-,166	
	W2t_1	,124	,188	
	W3t_1	-,158	,619	
	W4t_1	,048	,111	
	(Bias)			,161
Hidden Layer 1	H(1:1)			,373
	H(1:2)			,068

Lampiran 43. Nilai RMSE Data *Inflow* Model *hybrid* GSTARX-DLNN Bobot Seragam

Model	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSSTARX-DLNN (8,1,1,1)	482,701	172,413	154,064	97,667	1065,138	473,131	445,988	196,829
GSSTARX-DLNN (8,1,2,1)	482,333	172,418	153,978	97,649	1063,899	473,775	443,779	197,064
GSSTARX-DLNN (8,1,3,1)	483,283	172,467	154,210	97,565	1064,903	475,692	443,869	196,200
GSSTARX-DLNN (8,1,4,1)	482,452	172,314	154,358	97,540	1065,429	472,612	447,320	196,092
GSSTARX-DLNN (8,1,5,1)	482,233	172,307	154,327	97,660	1063,093	473,241	444,924	196,169
GSSTARX-DLNN (8,2,1,1)	482,312	172,390	153,798	97,501	1062,450	474,887	444,005	196,746
GSSTARX-DLNN (8,2,2,1)	482,522	172,328	154,245	97,497	1063,883	473,671	445,574	197,332
GSSTARX-DLNN (8,2,3,1)	482,071	172,151	154,744	97,930	1066,417	472,122	449,121	196,183
GSSTARX-DLNN (8,2,4,1)	483,173	172,341	155,211	98,106	1066,223	473,831	446,781	198,767
GSSTARX-DLNN (8,2,5,1)	482,636	172,449	153,940	97,610	1065,835	474,562	445,166	198,062
GSSTARX-DLNN (8,3,1,1)	482,371	172,413	154,073	97,662	1063,919	473,347	445,647	197,387
GSSTARX-DLNN (8,3,2,1)	481,014	172,687	155,489	97,693	1061,914	470,647	450,853	198,244
GSSTARX-DLNN (8,3,3,1)	482,044	172,317	153,489	97,360	1059,867	473,709	440,370	196,834
GSSTARX-DLNN (8,3,4,1)	482,471	172,372	153,837	97,349	1065,805	470,857	446,108	199,854
GSSTARX-DLNN (8,3,5,1)	482,941	172,089	154,175	97,811	1066,883	470,850	444,715	195,180
GSSTARX-DLNN (8,4,1,1)	482,344	172,387	154,273	97,669	1064,115	473,617	444,927	197,761
GSSTARX-DLNN (8,4,2,1)	483,005	173,125	153,649	98,501	1065,505	481,658	445,129	196,220
GSSTARX-DLNN (8,4,3,1)	481,574	172,510	153,873	97,800	1060,780	474,036	445,957	199,288
GSSTARX-DLNN (8,4,4,1)	480,670	172,793	157,112	97,753	1060,268	468,775	455,420	198,290
GSSTARX-DLNN (8,4,5,1)	481,478	173,093	155,933	99,390	1059,977	487,751	433,293	198,795
GSSTARX-DLNN (8,5,1,1)	482,122	172,571	154,355	97,655	1063,755	472,762	446,071	197,736
GSSTARX-DLNN (8,5,2,1)	480,303	173,080	153,908	100,153	1059,997	472,174	440,780	207,040
GSSTARX-DLNN (8,5,3,1)	481,842	172,237	154,736	97,842	1059,258	475,477	450,541	198,829
GSSTARX-DLNN (8,5,4,1)	480,200	172,431	154,194	98,225	1060,960	468,322	445,617	194,499
GSSTARX-DLNN (8,5,5,1)	480,440	172,629	155,791	97,849	1059,827	468,742	452,764	197,106
GSSTARX-DLNN (8,10,1,1)	482,255	172,495	154,421	97,738	1063,480	474,205	446,465	196,171
GSSTARX-DLNN (8,10,2,1)	482,585	172,231	153,787	97,753	1063,759	472,678	442,857	194,982
GSSTARX-DLNN (8,10,3,1)	478,943	172,763	156,385	99,479	1057,723	466,569	453,217	192,577
GSSTARX-DLNN (8,10,4,1)*	478,623	174,349	153,226	97,692	1047,469	464,225	436,855	198,192
GSSTARX-DLNN (8,10,5,1)	474,840	172,246	155,434	103,877	1032,434	475,437	432,158	207,890
GSSTARX-DLNN (8,15,1,1)	482,162	172,641	154,172	97,694	1064,829	472,746	441,990	198,443
GSSTARX-DLNN (8,15,2,1)	475,852	172,786	155,154	100,099	1050,107	481,068	430,010	205,871
GSSTARX-DLNN (8,15,3,1)	482,026	172,298	154,894	97,347	1062,478	476,446	448,305	195,749
GSSTARX-DLNN (8,15,4,1)	478,612	173,794	156,694	104,242	1061,768	484,591	421,173	205,146
GSSTARX-DLNN (8,15,5,1)	471,650	174,206	154,204	103,078	1046,246	486,322	433,341	207,978

Ket: *model terbaik

Lampiran 44. Nilai RMSE Data *Inflow* Model *hybrid* GSTARX-DLNN Bobot Invers Jarak

Model	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSSTARX-DLNN (8,1,1,1)	482,541	172,403	154,168	97,615	1064,639	473,630	446,351	197,138
GSSTARX-DLNN (8,1,2,1)	482,298	172,408	153,962	97,646	1063,832	473,792	443,626	197,036
GSSTARX-DLNN (8,1,3,1)	483,303	172,462	154,209	97,563	1064,896	475,659	443,859	196,196
GSSTARX-DLNN (8,1,4,1)	482,455	172,330	154,354	97,540	1065,421	472,661	447,320	196,095
GSSTARX-DLNN (8,1,5,1)	482,027	172,306	154,328	97,673	1062,467	473,439	444,737	196,195
GSSTARX-DLNN (8,2,1,1)	482,135	172,263	153,615	97,584	1063,409	473,879	444,350	196,825
GSSTARX-DLNN (8,2,2,1)	482,481	172,338	154,324	97,465	1063,419	473,534	445,764	197,025
GSSTARX-DLNN (8,2,3,1)	480,141	172,343	154,201	98,025	1058,292	473,121	430,418	199,353
GSSTARX-DLNN (8,2,4,1)	483,175	172,325	155,195	98,077	1066,033	473,918	446,453	198,537
GSSTARX-DLNN (8,2,5,1)	482,646	172,422	153,964	97,610	1065,580	474,435	445,385	197,920
GSSTARX-DLNN (8,3,1,1)	482,353	172,412	154,070	97,664	1063,894	473,343	445,681	197,403
GSSTARX-DLNN (8,3,2,1)	480,931	172,672	155,481	97,680	1061,935	470,634	450,784	198,177
GSSTARX-DLNN (8,3,3,1)	473,734	175,639	155,505	98,912	1045,981	488,575	437,628	200,318
GSSTARX-DLNN (8,3,4,1)	482,498	172,393	153,851	97,298	1065,665	471,135	446,344	199,606
GSSTARX-DLNN (8,3,5,1)	482,860	172,095	154,137	97,815	1066,148	470,721	444,284	195,010
GSSTARX-DLNN (8,4,1,1)	482,320	172,393	154,281	97,671	1064,074	473,636	444,889	197,823
GSSTARX-DLNN (8,4,2,1)	483,059	173,138	153,644	98,533	1065,663	481,700	445,124	196,397
GSSTARX-DLNN (8,4,3,1)	481,035	172,538	153,784	97,837	1059,113	473,939	446,341	199,853
GSSTARX-DLNN (8,4,4,1)	480,655	172,867	157,077	97,730	1059,867	468,772	455,437	198,173
GSSTARX-DLNN (8,4,5,1)	481,405	173,044	155,901	99,457	1059,864	487,616	433,371	198,961
GSSTARX-DLNN (8,5,1,1)	482,430	172,309	153,944	97,721	1064,780	474,165	445,863	196,640
GSSTARX-DLNN (8,5,2,1)	479,805	173,010	153,883	100,361	1058,164	473,218	440,007	207,242
GSSTARX-DLNN (8,5,3,1)	481,893	172,182	154,925	97,822	1059,844	475,978	449,427	199,411
GSSTARX-DLNN (8,5,4,1)	479,911	172,567	154,286	98,147	1060,202	467,428	445,912	194,616
GSSTARX-DLNN (8,5,5,1)	480,144	172,651	155,883	97,832	1059,506	468,763	453,059	197,055
GSSTARX-DLNN (8,10,1,1)	482,230	172,489	154,433	97,742	1063,428	474,214	446,457	196,166
GSSTARX-DLNN (8,10,2,1)	482,580	172,250	153,841	97,744	1063,888	472,847	443,362	195,299
GSSTARX-DLNN (8,10,3,1)	478,507	172,783	156,569	99,375	1057,212	466,470	453,692	192,892
GSSTARX-DLNN (8,10,4,1)	482,361	173,522	156,096	100,234	1075,779	468,703	444,616	204,054
GSSTARX-DLNN (8,10,5,1)	474,053	172,344	155,728	103,735	1031,732	475,637	431,226	206,896
GSSTARX-DLNN (8,15,1,1)	482,056	171,852	154,005	97,367	1058,958	464,395	448,305	194,163
GSSTARX-DLNN (8,15,2,1)	475,329	172,163	155,070	100,399	1046,712	463,919	444,252	200,232
GSSTARX-DLNN (8,15,3,1)	481,819	172,338	154,994	97,331	1062,075	477,286	448,964	195,780
GSSTARX-DLNN (8,15,4,1)*	469,467	172,467	157,712	102,492	1025,883	466,883	447,812	191,099
GSSTARX-DLNN (8,15,5,1)	469,995	174,569	154,226	102,471	1044,016	487,409	433,852	206,331

Ket: *model terbaik

Lampiran 45. Nilai RMSE Data *Inflow* Model *hybrid* GSTARX-DLNN Bobot NIKSP

Model	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-DLNN (8,1,1,1)	482,482	172,398	154,147	97,695	1064,152	473,196	446,502	197,517
GSTARX-DLNN (8,1,2,1)	481,973	172,461	153,739	96,921	1061,307	468,267	446,469	188,858
GSTARX-DLNN (8,1,3,1)	483,238	172,406	154,664	97,479	1064,959	474,437	448,418	195,918
GSTARX-DLNN (8,1,4,1)	481,856	172,601	154,032	97,639	1061,843	471,150	443,588	198,253
GSTARX-DLNN (8,1,5,1)	482,507	172,372	153,937	97,521	1063,915	473,859	444,279	195,853
GSTARX-DLNN (8,2,1,1)	482,199	172,433	153,854	97,595	1064,158	475,800	445,085	196,638
GSTARX-DLNN (8,2,2,1)	482,471	172,313	154,412	97,302	1063,183	474,285	446,868	194,405
GSTARX-DLNN (8,2,3,1)	482,120	172,068	153,436	97,130	1064,944	473,515	448,993	187,306
GSTARX-DLNN (8,2,4,1)	483,237	172,357	154,540	97,142	1066,160	474,053	445,013	194,366
GSTARX-DLNN (8,2,5,1)	481,843	172,539	154,149	98,022	1063,492	471,410	445,927	197,892
GSTARX-DLNN (8,3,1,1)	482,372	172,416	154,099	97,654	1063,935	473,390	445,959	197,343
GSTARX-DLNN (8,3,2,1)	480,620	172,962	154,438	97,390	1060,315	471,608	440,176	195,221
GSTARX-DLNN (8,3,3,1)	482,162	172,372	153,928	96,940	1060,036	472,968	451,876	187,052
GSTARX-DLNN (8,3,4,1)	482,411	172,415	153,686	97,455	1066,220	474,200	443,115	198,088
GSTARX-DLNN (8,3,5,1)	483,238	172,103	153,785	98,387	1066,572	472,020	441,810	201,494
GSTARX-DLNN (8,4,1,1)	481,868	172,346	154,711	97,968	1061,963	473,401	446,796	199,977
GSTARX-DLNN (8,4,2,1)	480,998	172,351	154,399	98,936	1057,429	476,671	446,289	203,676
GSTARX-DLNN (8,4,3,1)	484,081	172,424	153,962	97,367	1070,380	473,657	447,252	192,800
GSTARX-DLNN (8,4,4,1)	480,655	172,648	155,498	97,347	1060,077	472,401	447,659	192,780
GSTARX-DLNN (8,4,5,1)	477,930	173,435	159,002	97,638	1050,652	473,171	460,275	196,041
GSTARX-DLNN (8,5,1,1)	482,462	172,356	154,090	97,742	1064,545	474,236	446,974	197,812
GSTARX-DLNN (8,5,2,1)	480,191	173,347	153,683	98,777	1054,967	473,694	437,764	196,533
GSTARX-DLNN (8,5,3,1)	476,424	172,243	154,565	100,095	1047,072	483,009	451,539	207,379
GSTARX-DLNN (8,5,4,1)	481,479	172,259	153,925	98,500	1062,391	473,320	445,600	196,331
GSTARX-DLNN (8,5,5,1)	484,668	172,593	153,359	97,888	1064,902	480,112	438,022	198,498
GSTARX-DLNN (8,10,1,1)	482,469	172,421	154,284	97,633	1064,235	473,313	447,042	197,451
GSTARX-DLNN (8,10,2,1)	482,407	172,374	154,425	97,691	1065,302	474,077	445,592	196,660
GSTARX-DLNN (8,10,3,1)	478,407	171,917	155,870	100,057	1057,776	470,891	442,810	197,875
GSTARX-DLNN (8,10,4,1)	482,385	174,545	155,007	97,268	1068,739	479,405	444,943	184,954
GSTARX-DLNN (8,10,5,1)	475,841	173,149	152,881	98,251	1048,735	475,949	440,517	190,520
GSTARX-DLNN (8,15,1,1)	481,821	172,364	154,172	98,396	1061,592	472,390	449,527	202,193
GSTARX-DLNN (8,15,2,1)*	470,714	173,331	157,041	102,862	1024,987	473,623	437,273	202,429
GSTARX-DLNN (8,15,3,1)	477,697	172,782	157,955	99,207	1050,925	475,380	450,124	183,717
GSTARX-DLNN (8,15,4,1)	479,433	174,558	159,120	97,434	1064,899	474,400	463,422	189,161
GSTARX-DLNN (8,15,5,1)	473,963	172,302	154,557	99,173	1053,460	463,678	446,202	176,689

Ket: *model terbaik

Lampiran 46. Estimasi Parameter Model *hybrid* GSTAR-DLNN(8,15,4,1) Data *Inflow*

Predictor	Parameter Estimates																
	Hidden Layer 1										Hidden Layer 2						
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)	H(2:1)	H(2:4)
(Bias)	-.490	-.148	-.177	-.109	-.165	-.377	-.565	-.568	-.021	-.332	-.075	.548	-.499	-.218	-.322		
N1_1	-.295	-.400	-.288	-.044	.388	.619	.211	.017	.793	.225	-.123	-.125	-.380	-.513	.087		
N2_1	-.195	.168	.002	.238	.056	.108	-.043	-.355	.430	.326	-.167	.205	.128	.289	-.302		
N3_1	-.243	.289	.359	.334	.466	.530	-.240	.457	-.354	-.201	-.366	-.550	.292	.045	.028		
N4_1	.245	-.204	-.011	-.474	.277	.379	-.346	-.192	.215	-.737	.041	-.231	-.321	-.005	.222		
W1_1	-.202	-.055	.265	.136	.254	.232	-.231	-.350	.324	-.372	.369	.322	-.423	.236	-.437		
W2_1	.163	.138	.281	-.268	-.284	-.262	-.270	-.459	.158	.501	-.258	.446	-.540	.142	-.086		
W3_1	-.109	-.184	-.174	-.553	-.161	-.338	.231	-.458	-.125	-.014	.305	.150	.335	-.214	-.123		
W4_1	.191	.087	-.140	-.068	.251	-.448	-.136	-.415	-.450	.341	.171	-.247	.369	.243	-.130		
(Bias)																-.710	.253
H(1:1)																-.230	.393
H(1:2)																-.176	.321
H(1:3)																.143	-.497
H(1:4)																.198	.793
H(1:5)																-.445	.282
H(1:6)																-.642	-.440
H(1:7)																-.163	-.417
H(1:8)																.393	.016
H(1:9)																-.118	-.074
H(1:10)																.305	-.376
H(1:11)																.117	.032
H(1:12)																.698	.199
H(1:13)																-.240	.622
H(1:14)																-.395	-.051
H(1:15)																-.543	-.017
(Bias)																	.040
H(2:1)																	-.152
H(2:2)																	-.081
H(2:3)																	-.348
H(2:4)																	-.107

Lampiran 47. Nilai RMSE Data *Outflow Model hybrid* GSTARX-FFNN

Model (bobot Seragam)	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-FFNN (8,1,1)	464,377	124,136	205,970	99,504	965,623	508,056	460,396	301,116
GSTARX-FFNN (8,2,1)	463,704	123,605	205,268	99,214	965,729	505,569	464,652	287,179
GSTARX-FFNN (8,3,1)	464,650	124,304	204,519	99,324	956,323	503,900	457,863	300,812
GSTARX-FFNN (8,4,1)	464,268	124,025	205,129	98,334	955,782	503,497	457,156	300,695
GSTARX-FFNN (8,5,1)*	461,064	121,696	201,624	98,675	966,487	510,740	434,344	292,193
GSTARX-FFNN (8,10,1)	461,840	124,994	202,952	104,856	1012,706	541,744	409,532	311,616
GSTARX-FFNN (8,15,1)	469,586	129,387	206,686	103,219	946,216	507,494	450,678	288,284
Ket: *model terbaik								
Model (bobot Invers Jarak)	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-FFNN (8,1,1)	464,190	124,406	205,510	99,468	962,418	502,210	461,073	301,776
GSTARX-FFNN (8,2,1)	464,239	125,880	206,894	97,688	960,198	507,588	466,640	296,414
GSTARX-FFNN (8,3,1)	463,928	124,948	207,098	97,535	968,129	500,317	465,621	294,467
GSTARX-FFNN (8,4,1)	463,564	123,973	205,934	99,094	965,661	499,096	462,085	297,344
GSTARX-FFNN (8,5,1)	463,537	123,137	203,622	98,877	947,204	502,392	443,508	286,592
GSTARX-FFNN (8,10,1)	463,256	122,849	206,603	96,716	972,525	509,009	455,001	298,548
GSTARX-FFNN (8,15,1)*	457,378	120,768	198,726	95,639	1008,180	507,027	399,580	284,916
Ket: *model terbaik								
Model (bobot NIKSP)	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-FFNN (8,1,1)	466,153	124,422	205,991	100,711	953,840	511,275	456,274	299,074
GSTARX-FFNN (8,2,1)	464,500	124,623	205,098	99,181	961,562	498,442	457,539	300,933
GSTARX-FFNN (8,3,1)*	464,702	125,385	204,658	98,019	958,290	502,646	460,931	294,794
GSTARX-FFNN (8,4,1)	463,958	125,164	205,469	98,663	961,125	512,883	459,246	299,703
GSTARX-FFNN (8,5,1)	462,632	123,354	203,441	98,957	971,152	502,726	437,796	306,718
GSTARX-FFNN (8,10,1)	462,237	125,150	205,847	103,196	948,600	518,828	472,408	292,314
GSTARX-FFNN (8,15,1)	463,686	131,132	205,372	107,416	989,985	514,473	452,552	299,055
Ket: *model terbaik								

Lampiran 48. Estimasi Parameter Model *hybrid* GSTAR-FFNN(8,15,1) Data *Outflow*

Predictor	Parameter Estimates															
	Predicted															
	Hidden Layer 1															
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)	Output Layer
(Bias)	-,075	-,264	,487	,018	-,382	-,442	-,122	-,507	,040	,391	,393	,342	,472	-,310	,439	Nt
N1t_1	,102	,370	,101	-,371	-,019	,363	,422	-,333	,343	,412	,111	-,360	,247	,319	-,174	
N2t_1	-,170	-,351	-,216	-,233	-,395	,148	-,309	,088	-,449	,259	,455	-,142	-,297	-,342	,110	
N3t_1	-,395	-,357	-,225	-,225	,172	-,355	-,362	,136	,249	,371	,173	,467	,451	-,422	-,262	
N4t_1	,059	-,378	-,304	-,192	,435	-,382	-,009	-,448	-,012	,156	-,368	,287	-,070	,330	,208	
W1_1	,267	,178	,316	-,324	-,396	,345	-,310	,389	-,153	-,108	-,326	-,203	,136	,103	-,107	
W2_1	,388	,268	-,120	,151	,274	,025	-,054	-,109	,185	,383	,494	,033	,333	-,471	-,320	
W3_1	,405	-,094	-,054	,342	,199	-,136	,516	-,387	,372	-,086	-,210	,266	-,159	-,037	,458	
W4_1	,432	,055	-,289	-,400	,304	-,285	-,320	-,317	-,388	-,354	-,336	,001	,028	,135	-,275	-,312
(Bias)																-,132
H(1:1)																,171
H(1:2)																,262
H(1:3)																-,146
H(1:4)																,005
H(1:5)																-,051
H(1:6)																-,402
H(1:7)																,137
H(1:8)																-,041
H(1:9)																,135
H(1:10)																,050
H(1:11)																,378
H(1:12)																,036
H(1:13)																,074
H(1:14)																,220
H(1:15)																

Lampiran 49. Nilai RMSE Data *Outflow Model hybrid* GSTARX-DLNN Bobot Seragam

Model	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSSTARX-DLNN (8,1,1,1)	463,356	124,670	205,473	98,421	955,100	499,972	470,748	295,568
GSSTARX-DLNN (8,1,2,1)	464,234	124,833	204,880	99,395	964,655	500,180	456,108	301,441
GSSTARX-DLNN (8,1,3,1)	464,120	124,276	205,277	99,675	962,354	503,787	462,536	301,735
GSSTARX-DLNN (8,1,4,1)	464,012	124,770	205,506	99,461	962,133	498,013	462,861	301,796
GSSTARX-DLNN (8,1,5,1)	464,206	124,582	205,349	99,991	965,075	501,503	459,270	303,083
GSSTARX-DLNN (8,2,1,1)	464,101	124,742	205,038	99,676	961,978	500,355	457,415	302,394
GSSTARX-DLNN (8,2,2,1)	464,286	124,466	204,989	99,656	961,620	500,718	458,768	300,868
GSSTARX-DLNN (8,2,3,1)	463,618	125,301	205,205	97,785	959,198	494,737	455,302	292,544
GSSTARX-DLNN (8,2,4,1)	464,076	124,691	205,750	99,269	962,968	499,039	460,516	299,842
GSSTARX-DLNN (8,2,5,1)	464,570	123,799	205,443	99,264	954,660	502,748	462,005	296,801
GSSTARX-DLNN (8,3,1,1)	464,511	124,211	205,613	98,772	960,405	501,753	458,161	298,389
GSSTARX-DLNN (8,3,2,1)	464,061	124,377	205,372	99,783	963,667	502,397	459,114	301,161
GSSTARX-DLNN (8,3,3,1)	464,278	123,795	205,562	99,731	959,340	503,547	465,106	301,421
GSSTARX-DLNN (8,3,4,1)	464,698	124,378	206,375	97,703	961,476	501,679	470,236	296,184
GSSTARX-DLNN (8,3,5,1)	464,122	124,432	204,586	98,322	961,950	498,640	455,680	289,454
GSSTARX-DLNN (8,4,1,1)	464,460	124,197	205,090	99,805	958,688	503,827	458,420	301,243
GSSTARX-DLNN (8,4,2,1)	464,360	124,320	205,153	99,523	960,536	501,157	457,963	300,584
GSSTARX-DLNN (8,4,3,1)	464,505	124,713	206,541	102,499	955,613	505,687	454,374	290,605
GSSTARX-DLNN (8,4,4,1)	464,135	124,611	206,265	98,433	960,961	499,644	461,753	298,965
GSSTARX-DLNN (8,4,5,1)	464,446	124,122	204,831	99,666	955,430	495,257	445,531	297,962
GSSTARX-DLNN (8,5,1,1)	465,054	124,405	205,833	99,666	953,391	504,907	463,063	294,163
GSSTARX-DLNN (8,5,2,1)	464,442	124,948	205,644	98,533	963,990	504,700	459,446	298,012
GSSTARX-DLNN (8,5,3,1)	464,685	124,107	206,460	99,323	953,187	510,353	450,094	296,601
GSSTARX-DLNN (8,5,4,1)	465,589	124,254	204,988	97,510	960,050	502,004	458,456	297,599
GSSTARX-DLNN (8,5,5,1)	464,336	124,819	204,650	100,336	958,530	502,610	456,943	300,657
GSSTARX-DLNN (8,10,1,1)	464,153	124,060	205,274	99,356	961,462	501,323	463,451	299,083
GSSTARX-DLNN (8,10,2,1)	463,869	126,645	205,325	99,292	957,817	498,612	460,886	301,708
GSSTARX-DLNN (8,10,3,1)	464,672	125,413	205,630	100,628	967,502	502,773	455,542	306,795
GSSTARX-DLNN (8,10,4,1)	463,732	125,828	207,014	97,301	967,989	492,405	460,350	296,268
GSSTARX-DLNN (8,10,5,1)	464,549	124,450	207,216	97,280	957,219	504,616	456,659	297,933
GSSTARX-DLNN (8,15,1,1)	464,133	124,297	205,246	99,655	961,753	500,607	461,139	301,861
GSSTARX-DLNN (8,15,2,1)	462,985	124,094	206,391	98,917	960,061	507,578	469,214	297,541
GSSTARX-DLNN (8,15,3,1)	465,556	124,429	205,287	100,429	944,206	509,688	462,007	294,686
GSSTARX-DLNN (8,15,4,1)	463,425	123,905	202,463	98,475	962,787	492,929	443,431	281,418
GSSTARX-DLNN (8,15,5,1)*	464,447	126,085	200,123	99,105	933,073	513,293	435,772	294,533

Ket: *model terbaik

Lampiran 50. Nilai RMSE Data *Outflow* Model *hybrid* GSTARX-DLNN Bobot Invers jarak

Model	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSSTARX-DLNN (8,1,1,1)	464,486	124,575	205,249	100,376	963,642	500,536	456,473	302,937
GSSTARX-DLNN (8,1,2,1)	464,492	124,285	204,050	100,301	950,315	508,400	453,635	302,050
GSSTARX-DLNN (8,1,3,1)	464,202	123,867	205,275	100,031	954,926	502,049	463,096	296,664
GSSTARX-DLNN (8,1,4,1)	464,018	125,048	205,374	99,534	966,007	501,668	458,811	302,619
GSSTARX-DLNN (8,1,5,1)	464,230	124,286	204,946	99,272	965,338	504,815	455,452	301,261
GSSTARX-DLNN (8,2,1,1)	464,683	124,031	205,063	99,195	959,867	506,672	457,255	296,952
GSSTARX-DLNN (8,2,2,1)	464,479	124,282	205,402	99,764	958,316	502,145	459,605	298,401
GSSTARX-DLNN (8,2,3,1)	463,898	124,740	205,707	98,955	957,212	498,502	456,664	298,117
GSSTARX-DLNN (8,2,4,1)	464,584	124,304	204,607	100,239	955,815	504,505	456,505	301,141
GSSTARX-DLNN (8,2,5,1)	464,303	124,567	205,167	99,195	963,511	498,522	460,245	300,353
GSSTARX-DLNN (8,3,1,1)	465,018	124,321	205,790	99,713	953,834	505,322	462,413	294,487
GSSTARX-DLNN (8,3,2,1)	464,126	124,836	205,063	99,574	962,404	497,188	456,511	300,920
GSSTARX-DLNN (8,3,3,1)	465,887	125,853	207,537	101,411	943,115	503,485	466,201	292,605
GSSTARX-DLNN (8,3,4,1)	465,216	124,600	207,398	99,571	948,876	503,987	471,452	285,649
GSSTARX-DLNN (8,3,5,1)	464,513	123,964	204,641	98,361	952,564	501,017	457,233	297,948
GSSTARX-DLNN (8,4,1,1)	464,315	124,355	205,183	99,758	960,926	501,597	459,607	301,349
GSSTARX-DLNN (8,4,2,1)	464,791	124,354	204,959	98,540	954,608	498,967	453,951	297,125
GSSTARX-DLNN (8,4,3,1)	464,140	124,093	204,916	100,026	961,901	498,310	456,968	300,343
GSSTARX-DLNN (8,4,4,1)	464,114	124,792	205,147	99,699	961,611	500,790	452,985	301,755
GSSTARX-DLNN (8,4,5,1)	463,768	124,929	203,316	99,927	960,409	491,730	455,251	298,088
GSSTARX-DLNN (8,5,1,1)	464,264	124,470	205,126	99,788	962,030	502,048	458,066	302,428
GSSTARX-DLNN (8,5,2,1)	464,324	124,340	204,706	99,304	956,612	500,429	456,004	299,694
GSSTARX-DLNN (8,5,3,1)	464,300	124,593	204,673	99,249	961,413	503,179	454,662	301,462
GSSTARX-DLNN (8,5,4,1)	464,279	125,562	204,149	101,113	963,277	495,174	456,441	301,681
GSSTARX-DLNN (8,5,5,1)	464,253	125,241	205,420	97,987	959,293	497,330	453,609	298,663
GSSTARX-DLNN (8,10,1,1)	464,500	124,229	205,310	99,532	959,187	502,499	460,458	298,985
GSSTARX-DLNN (8,10,2,1)	464,040	124,511	205,756	100,316	962,847	500,180	459,479	302,400
GSSTARX-DLNN (8,10,3,1)	464,331	124,335	205,221	99,900	961,028	501,878	455,397	300,446
GSSTARX-DLNN (8,10,4,1)	464,490	124,960	203,975	97,877	957,106	508,709	445,123	296,993
GSSTARX-DLNN (8,10,5,1)*	464,881	125,780	204,756	97,318	944,847	500,736	454,558	286,515
GSSTARX-DLNN (8,15,1,1)	464,231	124,406	205,329	99,746	965,214	502,358	461,095	301,982
GSSTARX-DLNN (8,15,2,1)	463,968	124,853	205,238	100,153	962,659	498,615	458,423	302,488
GSSTARX-DLNN (8,15,3,1)	464,477	124,274	204,393	98,883	947,273	512,802	457,868	297,363
GSSTARX-DLNN (8,15,4,1)	465,881	123,468	203,513	97,659	941,170	503,738	454,382	296,869
GSSTARX-DLNN (8,15,5,1)	463,704	124,000	204,933	98,315	964,014	516,457	448,081	302,664

Ket: *model terbaik

Lampiran 51. Nilai RMSE Data *Outflow Model hybrid* GSTARX-DLNN Bobot NIKSP

Model	RMSE in Sample				RMSE out Sample			
	Surabaya	Malang	Kediri	Jember	Surabaya	Malang	Kediri	Jember
GSTARX-DLNN (8,1,1,1)	464,120	124,418	205,310	99,847	962,738	500,341	460,627	301,717
GSTARX-DLNN (8,1,2,1)	464,428	124,402	205,316	99,350	961,150	501,950	460,217	300,917
GSTARX-DLNN (8,1,3,1)	464,065	124,694	205,947	99,211	964,286	501,385	462,657	301,535
GSTARX-DLNN (8,1,4,1)	464,692	123,992	204,675	99,222	955,906	508,242	459,715	293,017
GSTARX-DLNN (8,1,5,1)	464,240	124,616	205,364	99,867	963,627	500,858	459,140	302,796
GSTARX-DLNN (8,2,1,1)	464,368	124,457	205,264	99,375	961,227	500,076	459,616	300,030
GSTARX-DLNN (8,2,2,1)	464,266	124,468	204,990	99,656	961,892	500,711	458,757	300,866
GSTARX-DLNN (8,2,3,1)	464,193	124,297	202,995	98,108	961,756	504,346	447,591	293,077
GSTARX-DLNN (8,2,4,1)	463,732	123,620	206,109	100,539	956,161	500,353	470,783	295,930
GSTARX-DLNN (8,2,5,1)	464,014	124,247	205,098	98,913	963,651	498,004	453,738	300,508
GSTARX-DLNN (8,3,1,1)	464,086	124,407	205,541	98,998	961,933	500,347	456,989	300,423
GSTARX-DLNN (8,3,2,1)	464,379	124,287	205,353	99,407	960,970	500,920	462,485	300,699
GSTARX-DLNN (8,3,3,1)	464,447	124,514	205,223	99,476	961,752	500,664	460,683	300,657
GSTARX-DLNN (8,3,4,1)	460,642	123,066	203,627	99,129	959,554	502,206	473,157	297,679
GSTARX-DLNN (8,3,5,1)	463,521	124,733	205,804	98,323	963,138	499,778	467,501	297,486
GSTARX-DLNN (8,4,1,1)	464,536	124,207	205,136	99,779	959,967	503,544	458,742	300,914
GSTARX-DLNN (8,4,2,1)	463,998	124,161	205,354	100,216	962,773	505,395	456,693	302,862
GSTARX-DLNN (8,4,3,1)	463,283	123,997	206,083	99,007	959,840	501,177	472,336	296,229
GSTARX-DLNN (8,4,4,1)	463,987	124,551	206,356	98,520	964,616	502,912	462,438	298,707
GSTARX-DLNN (8,4,5,1)	462,818	125,926	203,722	98,860	961,664	496,696	452,917	302,348
GSTARX-DLNN (8,5,1,1)	465,078	124,408	205,838	99,666	953,612	504,915	463,070	294,160
GSTARX-DLNN (8,5,2,1)	464,088	124,705	205,296	98,838	963,059	501,615	458,997	299,747
GSTARX-DLNN (8,5,3,1)	464,156	124,319	205,790	97,943	962,023	511,474	452,869	293,348
GSTARX-DLNN (8,5,4,1)	462,789	123,824	204,832	98,208	962,091	507,264	455,552	293,124
GSTARX-DLNN (8,5,5,1)	464,025	124,351	205,260	99,482	962,446	500,333	461,398	300,488
GSTARX-DLNN (8,10,1,1)	464,405	124,258	205,287	99,525	960,119	502,121	460,410	299,617
GSTARX-DLNN (8,10,2,1)	464,276	123,972	204,938	98,761	960,594	502,045	457,112	298,123
GSTARX-DLNN (8,10,3,1)	462,089	123,042	205,828	99,037	955,481	497,417	461,769	292,608
GSTARX-DLNN (8,10,4,1)	462,363	125,289	207,878	97,306	968,280	505,450	457,680	296,847
GSTARX-DLNN (8,10,5,1)	463,422	124,339	206,229	97,958	963,019	497,702	465,819	299,489
GSTARX-DLNN (8,15,1,1)	464,381	124,984	205,533	99,388	957,462	502,100	463,875	298,488
GSTARX-DLNN (8,15,2,1)	464,250	124,258	205,242	99,625	963,365	501,745	458,540	301,824
GSTARX-DLNN (8,15,3,1)	465,576	124,396	205,823	99,832	955,269	513,225	462,331	293,507
GSTARX-DLNN (8,15,4,1)*	463,845	123,491	202,433	98,269	954,208	495,066	444,023	281,165
GSTARX-DLNN (8,15,5,1)	463,623	125,613	200,410	98,591	945,770	508,150	433,954	293,985

Ket: *model terbaik

Lampiran 52. Estimasi Parameter Model *hybrid* GSTAR-DLNN(8,15,4,1) Data *Outflow*

Predictor	Parameter Estimates																				
	Hidden Layer 1															Hidden Layer 2					Output Layer
	H(1:1)	H(1:2)	H(1:3)	H(1:4)	H(1:5)	H(1:6)	H(1:7)	H(1:8)	H(1:9)	H(1:10)	H(1:11)	H(1:12)	H(1:13)	H(1:14)	H(1:15)	H(2:1)	H(2:2)	H(2:3)	H(2:4)		
Input Layer	(Bias)	,462	,076	-,218	-,444	-,461	,236	,019	,138	,433	,110	-,491	-,039	,282	,298	,283					
	N11_1	,092	-,408	,216	,142	-,185	,235	-,298	,155	,074	,264	,228	-,273	-,444	,382	-,019					
	N21_1	-,159	,405	,366	,337	-,482	-,471	,337	-,428	-,293	,404	-,372	,263	,226	-,344	,286					
	N31_1	-,190	-,169	-,174	-,354	,058	-,128	-,398	-,151	-,100	,321	,054	-,344	-,489	-,311	,173					
	N41_1	-,372	,131	,486	-,334	,470	-,346	,290	,309	,317	,075	,213	-,498	,019	-,360	,147					
	W11_1	-,218	-,171	,363	-,038	,089	,244	,224	,341	,122	-,191	,008	-,267	,285	,269	-,092					
	W21_1	,379	-,088	-,335	-,215	-,038	-,324	,069	,333	-,239	-,360	,460	-,417	,209	-,379	,189					
	W31_1	,139	-,101	,299	-,006	-,046	,487	,193	,243	,075	-,371	,137	,438	-,379	,323	,276					
	W41_1	,039	-,096	-,140	-,486	-,240	,463	-,461	-,480	,491	-,435	-,179	-,389	-,447	-,341	-,023	,368	,346	-,206	-,244	
	Hidden Layer 1	(Bias)																			
		H(1:1)																			
		H(1:2)																			
		H(1:3)																			
		H(1:4)																			
		H(1:5)																			
H(1:6)																					
H(1:7)																					
H(1:8)																					
H(1:9)																					
H(1:10)																					
H(1:11)																					
H(1:12)																					
H(1:13)																					
H(1:14)																					
Hidden Layer 2	H(1:15)																				
	(Bias)																				
	H(2:1)																				
	H(2:2)																				
	H(2:3)																				

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : I Made Gde Meranggi Dana

NRP : 06211650010028

Menyatakan bahwa data yang digunakan dalam Tesis/ ~~Disertasi~~ ini merupakan data sekunder yang diambil dari ~~penelitian/ buku/ Tugas Akhir/ Thesis/ Disertasi/~~ publikasi lainnya, yaitu:

Sumber : Bank Indonesia

Keterangan : Data *Inflow* dan *Outflow* di KPw BI Surabaya, Malang, Kediri, dan Jember

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat permalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Surabaya, 29 Januari 2018

Mengetahui,
Pembimbing Tesis

Mahasiswa

Dr. Suhartono, M.Sc.
NIP. 19710929 199512 1 001

I Made Gde Meranggi Dana
NRP. 06211650010028

BIOGRAFI PENULIS



Lahir di Lebih tanggal 3 Agustus 1994, I Made Gde Meranggi Dana mulai menekuni bidang *forecasting* saat kerja praktik di Kantor Perwakilan Bank Indonesia Provinsi Bali. Saat itu penulis menganalisis pengaruh kedatangan wisatawan terhadap laju inflasi di Bali menggunakan fungsi transfer. Pada tahun 2016, penulis memperoleh gelar sarjana sains di Institut Teknologi Sepuluh Nopember (ITS) dengan judul tugas akhir, “Peramalan *Inflow* dan *Outflow* Sebagai Proyeksi Kebutuhan Uang Kartal di Provinsi Bali Menggunakan Fungsi Transfer, TBATS, ARIMA, dan ARIMAX”. Kemudian penulis melanjutkan studi S2 di Departemen Statistika ITS melalui beasiswa BPP-DN *Fresh Graduate*. Penulis memperoleh gelar magister sains pada tahun 2018 setelah menyelesaikan tesis dengan judul, “Model *Hybrid* GSTARX-ANN untuk Peramalan Data *Space-Time* dengan Efek Variasi Kalender”. Untuk komentar, saran, atau diskusi lebih lanjut mengenai tesis ini, penulis bisa dihubungi melalui email: meranggidana@gmail.com. Hala Madrid!

Halaman ini sengaja dikosongkan